

Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина

Л.Г. Доросинский, Н.С. Виноградова

**ОБРАБОТКА СИГНАЛОВ
ОТ ПРОСТРАНСТВЕННО
РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ**

Монография

Москва
2023

УДК 621.312.01(076)

ББК 32.88

Д69

Рецензенты:

Иванов Вячеслав Элизбарович – доктор технических наук, профессор.

Часовских Виктор Петрович – доктор технических наук, профессор.

Доросинский Л.Г. Виноградова Н.С.

Д69

Обработка сигналов от пространственно распределённых целей: монография / Л.Г. Доросинский, Н.С. Виноградова. – М.: Издательский дом Академии Естествознания, 2023. – 348 с.

ISBN 978-5-91327-762-6

DOI 10.17513/nr.560

Книга посвящена решению теоретических и практических проблем обнаружения, изменения параметров и классификации пространственно-распределённых целей (ПРЦ) по отражённым сигналам и формируемым на их основе их радиолокационным изображениям (РЛИ).

Подобные проблемы возникают при радиолокационном обзоре воздушного и космического пространства, земной и водной поверхности с использованием различных радиотехнических систем: РЛС дальнего обнаружения, РЛС с синтезированием апертуры, размещённых на воздушных и космических носителях и многих других подобных систем.

В книге подробно рассмотрены методы синтеза и анализа алгоритмов обнаружения, оценки параметров и классификации ПРЦ, алгоритмы формирования РЛИ движущихся объектов.

Книга представляет интерес для специалистов, студентов и аспирантов, работающих в области разработки современных радиотехнических систем военного и гражданского назначения.

ISBN 978-5-91327-762-6

© Доросинский Л.Г. Виноградова Н.С., 2023

© ИД «Академия Естествознания»

© АНО «Академия Естествознания»

ВВЕДЕНИЕ

Проблема обнаружения, оценки параметров и классификации пространственно-распределённых целей была и остаётся определяющей при разработке и создании современных радиолокационных систем мониторинга космической, воздушной и наземной обстановки современными и перспективными радиолокационными средствами.

В настоящей работе названная проблема решается по отношению к двум типам пространственно-распределённых целей и соответственно двум типам радиолокационных систем. Во-первых, это задача наблюдения наземных и воздушных целей космическими системами с высоким разрешением по дальности и азимуту (РЛС с синтезированной апертурой), и, во-вторых, задача обработки сигналов от космических многоэлементных целей наземными средствами наблюдения.

В каждом из рассматриваемых случаев в работе получены модели принимаемых сигналов, синтезированы оптимальные и предложены квазиоптимальные (практически реализуемые) алгоритмы обнаружения сигналов от пространственно-распределённых целей, алгоритмы оценивания параметров названных сигналов, а также алгоритмы классификации целей по отражённым сигналам.

В работе получены необходимые выражения для определения эффективности обнаружения, оценивания и классификации и произведены соответствующие вычисления, что позволяет сформулировать практические рекомендации по выбору параметров используемых сигналов.

Особое внимание уделено исследованию возможностей практической реализации предлагаемых алгоритмов с использованием современных вычислительных мощностей, объёмов памяти и ограничений на время принятия решений.

Каждая глава монографии носит вполне законченный характер и может рассматриваться отдельно от общего текста. В связи с этим библиографический список приводится отдельно к каждой главе работы.

Настоящая монография, как представляется авторам, будет полезна разработчикам и исследователям современных радиолокационных систем

различного назначения, предназначенных для эффективной обработки сигналов от пространственно-распределённых целей, а также аспирантам и студентам, изучающим современные радиотехнические системы.

В.1. История дистанционного зондирования Земли из космоса [1]

Дистанционное зондирование Земли (ДЗЗ) – это широко распространённый метод извлечения информации о поверхности Земли и объектах на ней, атмосфере, океане, верхнем слое земной коры такими способами, когда регистрирующая аппаратура удалена от объекта наблюдения на значительное расстояние и размещена на движущемся носителе – летательном аппарате (ЛА): искусственном спутнике Земли, самолёте, беспилотном ЛА и др. [1, 3, 4]. При дистанционном зондировании существует функциональная связь между физическими параметрами, характеризующими состояние наблюдаемой поверхности, и регистрируемыми аппаратурой наблюдения вторичными параметрами собственного или отраженного излучения объекта. Измеряемые параметры электромагнитного излучения/отражения от поверхности после соответствующей обработки позволяют сделать практически полезные выводы о состоянии поверхности и прогнозировать названное состояние в интересах самых различных областей знаний.

Исторически первыми аппаратными средствами дистанционного зондирования служила фотография. Начиная со второй половины XX века доминирующую роль в области ДЗЗ стали играть космические средства наблюдения, такие, в частности, как разведывательные спутники (программы CORONA, ARGON, LANYARD), получающие фотоснимки земной поверхности с низких орбит.

В апреле 1960 первый метеорологический спутник был запущен в США. Он использовался для прогноза погоды, наблюдения за перемещением циклонов и других подобных задач.

Первым спутником для систематической съёмки больших участков поверхности стал TIROS-1 {Television and Infrared Observation Satellite). Для целей сельского хозяйства в 1972 году был запущен спутник ERTS-1 (Earth Resources Technology Satellite). Такого рода спутники используются и в настоящее время (серия Landsat).

В 1978 году был запущен первый спутник со сканирующей системой SEASAT. Первый французский спутник (SPOT) выведен на орбиту в 1985 году. Далее состоялись запуски индийского и японского спутников. Уже в 1975 году состоялся запуск китайского спутника.

Отметим основные тенденции развития космического зондирования.

- Разрешение космических снимков, полученных в метровом и дециметровом диапазоне волн, становится близким к фотоснимкам.

- Растёт удельный вес цифровых методов обработки и формирования снимков поверхности.

- Независимость радиолокационных методов наблюдения от времени суток и погодных условий делает названные методы широко используемыми и основными методами ДЗЗ.

- Растёт число коммерческих аппаратов: Landsat(США), SPOT (Франция), IRS(Индия), ALOS (Япония), Cartosat (Индия), спутники сверхвысокого разрешения Ikonos, QuickBird, GeoEye (США), в том числе радиолокационные TerraSAR-X, TanDEM-X, RapidEye (Германия).

Данные спутников комплексировуются с другими источниками информации, включая, так называемые, подспутниковые наблюдения.

Стереосъёмка даёт возможность формировать трёхмерное изображение наблюдаемого объекта.

Многозональная и гиперспектральная съёмка позволяют повысить эффективность дешифрирования изображения земной и водной поверхностей.

Многовременная съёмка – съёмка в заранее определенные даты для сравнительного анализа изображений, изменяющихся во времени.

Многополяризационная съёмка использует поляризационные отличия отражений от разных типов поверхностей.

В.2. Техника получения материалов дистанционного зондирования

При формировании изображений различных поверхностей используют разные спектральные диапазоны – световой, тепловой и радиодиапазон [2–4].

На световых снимках отображаются оптические характеристики объектов.

Использование приемников теплового излучения (тепловая съёмка) позволяет получить тепловые инфракрасные снимки.

Съемка в радиодиапазоне делится на пассивную (регистрация собственного излучения исследуемых объектов) и активную (регистрация отраженного радиоизлучения).

Радиолокационная съемка формирует изображения земной поверхности независимо от погодных условий, в дневное и ночное время.

Радиолокационная съемка Земли ведется в различных диапазонах длин волн (1 см – 1 м) или частот (40 ГГц – 300 МГц).

Радиолокационная информация особенно эффективна для целей картографирования территорий, преимущественно закрытых облачностью. В этом случае радиолокационные изображения существенно превосходят оптические.

При использовании информации о разности фаз отражённых сигналов радиолокационная интерферометрия) удаётся формировать карты высот элементов поверхности (спутники Cosmo-Skymed, TerraSAR-X, TanDEM-X определяют высоты с относительной погрешностью менее 2м).

Температурные неоднородности поверхности Земли, возникающие в результате неодинакового нагрева различных ее участков, являются источником информации при съёмке в инфракрасном диапазоне спектра электромагнитных колебаний. Яркость тона прямо пропорциональна интенсивности тепловой аномалии.

ИК-съемка может использоваться для изучения рельефа дна шельфа. Поскольку температура поверхности воды над более глубокими участками ниже, чем над мелкими, ИК-изображения дают возможность выделять формы рельефа дна.

Методы ДЗЗ позволяют существенно повысить эффективность картографирования земельных и водных ресурсов, почв, лесов, сельскохозяйственных посевов и городской инфраструктуры, оценки урожая и многое другое.

Примерами эффективного использования технологий дистанционного зондирования может служить краткий перечень отраслей их использования:

1. Землепользование и картографирование земельных ресурсов.
2. Исследования застройки городов.
3. Сельское хозяйство.
4. Картографирование грунтовых вод.

5. Борьба с наводнениями.
6. Гидроморфологические исследования.
7. Картографирование пустующих земель.
8. Региональное планирование.
9. Борьба с природными катастрофами.

В.3. РЛС с синтезированной апертурой

Радиолокатор с синтезированной апертурой (РСА) – это активный датчик, излучающий импульсный радиолокационный сигнал, оптимальная обработка которого на борту летательного аппарата позволяет получить радиолокационное изображение (РЛИ) подстилающей поверхности с высоким разрешением по дальности, благодаря широкополосности используемого сигнала и по азимуту за счёт, так называемого, процесса искусственного синтезирования апертуры антенны. Эффект искусственного синтезирования антенны создаётся вследствие когерентного накопления сигнала на достаточно протяжённом участке траектории полёта ЛА (порядка единиц километров). При таком размере раскрыва антенны в дециметровом диапазоне длин электромагнитных волн разрешение по двум координатам может достигать величин порядка единиц метров [3, 4].

Дополнительный эффект получения не только яркостных карт наблюдаемых участков местности, но и карт распределения высот этих участков обеспечивает интерферометрия – инструмент построения цифровых моделей рельефа поверхности.

Радиолокационные изображения, формируемые в РСА, позволяют решать следующие задачи:

- получение карт труднодоступных территорий, в том числе, покрытых густой растительностью;
- обновление элементов содержания топографических карт;
- построение цифровых моделей рельефа (ЦМР);
- мониторинг ледовой обстановки в арктических морях с целью уточнения положения береговой линии морей и обеспечения судоходства в сложных метеоусловиях;
- оперативный контроль морских экономических зон и районов хозяйственной деятельности;
- мониторинг чрезвычайных ситуаций (последствия стихийных бедствий и техногенных катастроф на море и на суше).

Среди большого количества задач, решаемых по радиолокационным изображениям земной поверхности, в настоящей работе мы сосредоточим основное внимание на задачах распознавания пространственно-распределённых объектов, другими словами пространственно-распределённых целей (ПРЦ). Примерами таких задач могут служить следующие: распознавание надводных кораблей, распознавание нефтяных пятен, анализ морского волнения и ледовых образований, и т. п.

В.4. Литература к Введению

1. Воробьёва А.А. Дистанционное зондирование Земли. Учебно-методическое пособие. СПб.: СПбУ ИТМО, 2012. 168 с.
2. Грант Бенджамин. Вид сверху. Потрясающие снимки Земли со спутников = Benjamin Grant. Overview. М.: Альпина Паблишер, 2018. 284 с. — ISBN 978-5-9614-6615-7.
3. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография. М.: Издательский дом Академии Естествознания, 2017. 212 с.
4. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. М.: Издательский дом Академии Естествознания, 2018. 264 с.

1. РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ (ОБЗОР СОВРЕМЕННОГО СОСТОЯНИЯ ПРОБЛЕМЫ)

В данном разделе приведён, как возможно покажется читателю, излишне подробный, хотя и сравнительно поверхностный обзор литературы, посвящённой методам обработки сигналов в системах ДЗЗ. Тем не менее, авторы считают размещение данного материала полезным и позволяющим исследователю избежать утомительной работы по поиску и анализу многочисленных источников, связанных с названной проблемой. В работе сознательно не приводятся сложные математические выражения, сопровождающие каждое исследование. Подробные ссылки на литературу безусловно помогут заинтересованному читателю самостоятельно ознакомиться с соответствующими подробностями.

Радиолокационные изображения (РЛИ) Земли из космоса являются неотъемлемыми составляющими современного дистанционного зондирования Земли (ДЗЗ). Использование технологии синтеза апертуры (РСА) позволяет достичь сопоставимого с оптическим диапазоном пространственного разрешения, что дает возможность осуществлять наблюдение широкого круга объектов, начиная от лесных вырубок и заканчивая практически точечными целями, такими как транспортные средства или элементы антропогенных конструкций. Регулярно растущий круг задач, решаемых методами ДЗЗ, приводит к необходимости разработки алгоритмов, позволяющих выполнять автоматизированные работы по поиску и оценке изменений на местности в режиме реального времени.

В настоящее время принято различать две группы методов, позволяющих решать подобные задачи: обучение с учителем, основанное на использовании априорной информации о пространственно-распределенных целях (ПРИЦ), и обучение без учителя, когда кластеризация изображений происходит в автоматическом режиме, основываясь исключительно на анализе наблюдаемых данных. Несмотря на то, что в области обработки оптических изображений за последние несколько десятилетий получены существенные результаты [1], проблема идентификации образов

на радиолокационных изображениях остается актуальной. В отличие от изображений оптического диапазона формирование РЛИ выполняется при боковом обзоре, что существенно искажает образы целей и вызывает появление радиолокационных теней, причем названные эффекты являются анизотропными, вследствие чего изображения одной и той же цели, полученные при разных ракурсах съемки, могут кардинально различаться [2, 3].

Наконец, неотъемлемой составляющей радиолокационных данных ДЗЗ является мультипликативный спекл-шум [4].

1.1. Формирование вспомогательных дешифровочных признаков

Достаточно большое количество методов классификации РЛИ осуществляется параллельно либо после предварительного преобразования пространства изображения в обобщённую частотную область. Такой прием позволяет, во-первых, эффективно обнаруживать объекты заданной формы с учетом возможных аффинных преобразований по отношению к распознаваемому объекту, во-вторых, выявлять текстуру и/или форму отдельных областей космоснимков. При дальнейшей работе в новом пространстве возможно использование различных классификаторов с сохранением логики их первоначальных алгоритмов [5–9]. Существует большое количество методов преобразования изображений в различные типы частотных пространств, используемых в области обработки изображений, среди которых исторически первым методом является Фурье-преобразование.

1.1.1. Фурье-преобразование

Анализ частот в сформированной Фурье-области позволяет обнаруживать образы выраженной линейной формы, как, например, антропогенные и геологические объекты [10]. Также этот метод оказался эффективным в задаче обнаружения морских судов [7], благодаря стабильной составляющей спектра для высококогерентных участков изображения, что показано для данных всего используемого в ДЗЗ радиодиапазона. Отмечено, что обнаружение объектов в частотной области показывает хорошие результаты даже в условиях интенсивного спекл-шума [11].

Более общим случаем является дробное преобразование Фурье [12], позволяющее установить временное местоположение конкретных спектральных составляющих, что имеет большое значение при рассмотрении нестационарных процессов. Названный подход дополнительно позволяет снизить объем анализируемых данных за счет отбрасывания высокочастотных компонент [11].

1.1.2. Преобразование Радона

Близким по содержанию к Фурье-преобразованию является преобразование Радона [13], отображающее исходное изображение в новое пространство таким образом, что прямые линии преобразуются в точку. За счет этого становится возможным обнаруживать прямолинейные участки на РЛИ. В частности, преобразование Радона показало себя как эффективный инструмент поиска быстроходных морских судов за счет идентификации оставляемых ими следов на водной поверхности [14, 15]. Как и Фурье-преобразование, преобразование Радона позволяет получать надежные результаты даже при классификации целей, слабо отличающихся своим контрастом [16–18].

1.1.3. Преобразование Хафа

Дальнейшим развитием преобразований пространства изображения в частотную область является преобразование Хафа [19], позволяющее определить размер и ориентацию прямолинейных отрезков изображений, и обобщённое преобразование Хафа [20], дополняющее метод таким образом, что становится возможным осуществлять обнаружение кривых произвольной формы. Такой подход эффективно используется в задачах обнаружения дорог, границ сельскохозяйственных угодий, взлетно-посадочных полос и других тонких слабоконтрастных линий на РЛИ [21–23].

1.1.4. Вейвлет-преобразование

Более общим подходом при работе в частотной области является группа вейвлет-преобразований [24], в общем случае отображающих пространство изображения в пространство более высокой размерности, в котором две из осей связаны с частотной областью, остальные – с какими-либо анализируемыми признаками, например, яркостью. Такой подход дополняет возможности Фурье-преобразования, позволяя через

анализ вейвлет-коэффициентов учитывать различные локальные особенности сигнала, ассоциированные с особенностями отдельных образов на РЛИ [25]. Указанный подход нашел широкое применение в задачах распознавания областей, обладающих характерными текстурными особенностями [6–9], границ объектов различной формы [18], линейных объектов заданной формы и точечных целей [8]. В частности, применение метода вейвлет-преобразований дает хорошие результаты в задачах распознавания морских судов на водной поверхности и детектирования участков возгораний на разновременных данных ДЗЗ в различных диапазонах [26–28].

Помимо указанных выше методов отображения в частотную область, существуют их различные модификации, а также и иные типы преобразований, используемые при обработке РЛИ, а именно, преобразования Лапласа, Гильберта и Рисса [29–31], а также разложение изображения на полиномы Цернике [32–34]. За исключением Фурье-преобразования и полиномов Цернике, все эти методы объединяет идея выбора системы опорных функций таким образом, чтобы они максимально адекватно представляли текстурные, геометрические и иные свойства распознаваемых объектов. В ряде специфических задачах, например, при обнаружении заданных изменений на разновременных изображениях, зачастую, возможно использование преобразований в частотную область как самостоятельного инструмента классификации, однако наиболее широкое применение в проблеме распознавания образов на РЛИ они находят в сочетании с различными классификаторами. Однако следует отметить возрастающую вычислительную сложность алгоритмов, использующих дополнительные дешифровочные признаки, поэтому даже в случае применения сравнительно простых классификаторов возникает проблема оптимизации вычислительной процедуры.

1.2. Методы снижения размерности

При распознавании и классификации РЛИ особенно остро встает проблема их размерности, поскольку современные радиолокационные системы ДЗЗ обеспечивают формирование изображений со строкой, содержащей, как правило, несколько тысяч элементов, а библиотеки признаков классов могут включать несколько десятков различных характеристик. Это приводит к так называемому «проклятию размерности», обусловленному требованиями исключительной мощности

вычислительных ресурсов, при этом лишь незначительная часть обрабатываемых данных является принципиальной для обеспечения надлежащего качества распознавания [35]. С учетом этого бывает необходимо снизить размерность исходных данных в целях дальнейшей оптимизации процедуры их обработки за счет перевода изображения из пространства пикселей в пространство признаков, причем в большинстве случаев такая процедура помогает улучшить точность классификации. Одним из наиболее распространенных методов снижения размерности является метод главных компонент.

1.2.1. Метод главных компонент

Суть метода главных компонент (Principal Component Analysis, PCA) заключается в представлении исходного массива данных в виде суммы компонент с коэффициентами, являющимися координатами векторов признаков в формируемом пространстве признаков. В качестве таких коэффициентов используются собственные значения ковариационной матрицы исходного изображения, за счет чего и достигается редукция размерности входного массива изображения с сохранением наиболее значимой информации. Применительно к задачам обработки РЛИ метод главных компонент используется в первую очередь как способ подавления спекл-шумов с целью последующей идентификации изменений на космических снимках, полученных в разное время и в разных условиях. Кроме того, метод PCA успешно применяется в сочетании с различными классификаторами, позволяя, с одной стороны, несколько ускорить процесс обработки, с другой стороны, увеличить точность распознавания [36–41].

1.2.2. Метод независимых компонент

Из анализа метода главных компонент следует, что наилучшие результаты его использования будут достигаться в случае, если исходное распределение данных мало отличается от нормального. В общем случае распределение элементов вектор-строки РЛИ подчинено гамма-распределению, которое может быть аппроксимировано нормальным только в отдельных ситуациях. Поэтому следующим этапом развития метода главных компонент становится метод независимых компонент (Independent Component Analysis, ICA), предполагающий использование данных, подчиненных произвольному и в общем

случае неизвестному распределению [42]. Для реализации этого преобразования используются оценки статистических моментов более высоких порядков и условия статистической независимости элементов вектора признаков, причем процедура расчета базисных векторов формируемого пространства зачастую связана со значительными вычислительными трудностями. Тем не менее, в сочетании с методом главных компонент для подавления спекл-шумов возможно распознавание морских судов с точностью более чем 95 % даже в условиях очень низкой контрастности целей [43], а использование различных классификаторов с учителем после применения метода независимых компонент демонстрирует точность распознавания не ниже 90 % на примере объектов базы MSTAR [44-45]. База MSTAR представляет собой серию РЛИ десяти различных транспортных средств военного назначения с пространственным разрешением 30 см и размером кадра 128×128 элементов, полученных в X-диапазоне при различных углах обзора. Это наиболее широко используемые тестовые изображения в работах, посвященных разработке и адаптации различных методов распознавания на РЛИ [46].

1.2.3. Низкоранговое матричное разложение

Еще одним методом снижения размерности исходных данных является низкоранговое матричное разложение (Low-Rank Matrix Factorization, LMF). В методе предполагается, что любой вектор признаков может быть представлен в виде произведения двух совместимых матриц, по крайней мере один из размеров которых меньше, чем любой из размеров исходных данных [47]. Процедура разложения достигается за счет минимизации квадрата некоторой нормы от разницы исходного вектора и произведения искоемых матриц. Применительно к задаче распознавания образов на РЛИ чаще всего используются две реализации низкорангового матричного разложения: NMF [48-49] и TSVD [3, 50-52].

1.3. Классификация без обучения

Классификация без обучения, или сегментация, представляет собой декомпозицию изображения на некоторые множества, называемые кластерами, без использования какой-либо априорной информации о параметрах классов. Полученные в результате кластеры полностью охватывают исходное изображение, причем элементы каждого из кластеров обладают

схожими характеристиками. Существует обширное количество разных подходов к процессу сегментации изображений, но применительно к РЛИ чаще всего используются следующие группы методов: пороговая обработка, кластеризация, алгоритмы с наращиванием областей, выделение границ, модели активного контура и марковские случайные поля.

1.3.1. Пороговая обработка

Пороговая обработка включает в себя простейшие алгоритмы сегментации и заключается в сопоставлении некоторого признака изображения с установленным заранее пороговым значением. Как правило, результат пороговой обработки представляет собой бинарное изображение, поэтому процедуру пороговой обработки иногда называют бинаризацией. В ряде случаев в качестве порогового значения может быть использована амплитуда либо некоторая функция от амплитуды РЛИ. Так, на данных ДЗЗ, обладающих различным типом поляризации, вертикально и горизонтально ориентированные объекты будут давать образы различной яркости, поэтому выбор в качестве порогового значения логарифма яркости для РЛИ дорог и мостов может быть успешно применен для сегментации изображения и дальнейшего распознавания таких объектов [53].

Существует три основных универсальных приема, лежащих в основе пороговой сегментации изображений РЛИ: анализ гистограммы изображения, расчет энтропии и метод Оцу (Otsu's method), заключающийся в анализе дисперсии изображения. В первой группе методов производится расчет и анализ различных параметров гистограммы, таких как высота и положение максимумов, степень асимметричности и кривизны, при этом роль исходного распределения элементов РЛИ, как правило, выступает гамма-распределение [54]. Порог устанавливается таким образом, чтобы минимизировать вероятность ошибочной классификации [54]. В отдельных случаях может быть использован порог Киттлера-Иллингворта [55]. Алгоритмы сегментации, основанные на анализе гистограмм изображений, демонстрируют высокую скорость обработки данных и в сочетании с методами предварительной пространственной адаптивной фильтрации [54, 56] дают эффективные результаты в задачах обнаружения изменений по данным [54, 57]. Приемы пороговой обработки могут быть

расширены на различные производные признаки, такие как Фурье-пространство и вейвлеты. Так, анализ асимметрии энергии вейвлетов позволяет осуществить сегментацию не только исходя из яркостных признаков фрагментов РЛИ, но и текстурных [58].

При сегментации, основанной на расчете энтропии, пороговое значение устанавливается таким образом, чтобы энтропия всего изображения принимала максимально возможное значение. Изначально метод предполагал использование для расчетов информационной энтропии по Шеннону, однако применительно к изображениям, полученным с помощью технологии РСА, классическое выражение Шеннона было подвергнуто различным модификациям, например, использованием весовых коэффициентов при подсчете энтропии для смежных областей [59]. Надежные результаты в задачах классификации РЛИ могут быть достигнуты с использованием выражений для энтропии Реньи и перекрестной энтропии, причем в обоих случаях выдвигается предположение об исходном гамма-распределении яркостей элементов РЛИ [60,61]. Применение алгоритма KFCG, основанного на использовании элементов матрицы совместной встречаемости [62], позволяет разбить исходное РЛИ на большое количество непересекающихся классов с учетом их текстуры.

Выбор порогового значения в методе Оцу основан на максимизации межклассовой дисперсии. Применительно к РЛИ используется двумерный метод Оцу, в котором рассчитываются значения двумерной дисперсии вдоль двух направлений – собственно значений яркости отдельных элементов и значений усредненной яркости в рамках некоторого окна. Такой подход позволяет выполнять эффективную бинаризацию изображений даже в условиях достаточно интенсивного шума [63]. Сегментация на основе двумерного метода Оцу показывает надежные результаты в задачах выделения объектов гидрографии [64] либо обнаружения различных образов на водной поверхности, например, следов разлива нефти [65]. В ряде случаев оказывается целесообразным производить расчет межклассовой дисперсии с учетом диагональных составляющих двумерного распределения в 2D-методе Оцу, что позволяет получить несколько более точные результаты [66].

1.3.2. Кластеризация

Кластеризация основана на использовании алгоритма К-средних значений, общая идея которого заключается в минимизации разброса признаков элементов кластеров по отношению к их центрам масс, при этом оценка центров масс вычисляется итерационно до тех пор, пока происходит изменение расстояния между кластерами [67]. Число формируемых классов устанавливается заранее и, в отличие от пороговой обработки, может быть произвольным. Из-за присутствия спекл-шума применительно к РЛИ метод в своей классической форме малоэффективен, однако может давать хорошие результаты при расчете различных производных характеристик исходного изображения, например, усреднённого значения, дисперсии и энтропии [68], либо применительно к задаче детектирования изменений – разностного и среднего отношения. В целом такой подход обеспечивает достаточно точные результаты сегментации в сочетании в высокой скоростью обработки [69]. Кроме того, возможно комбинирование метода кластеризации с приемами пороговой обработки, например, с методом Оцу [70].

Метод нечеткой кластеризации (С-средних, Fuzzy C-means, FCM), по сути, представляет собой усовершенствованный метод К-средних, когда оценивается вероятность принадлежности элементов изображения к каждому из кластеров. Центры кластеров итерационно рассчитываются с использованием элементов матрицы принадлежности, алгоритм выполняется до тех пор, пока значение функции потерь не перестает уменьшаться [71]. При этом необходимо знать закон исходного распределения, в качестве которого может быть использовано гамма-распределение либо распределения Накагами-Релея [72]. В целом процедура сегментации обозначенным методом занимает больше времени, однако результат оказывается точнее в сравнении с классическим подходом кластеризации [72, 73]. Модификация нечеткой кластеризации, когда центры масс кластеров рассчитываются как среднегармонические значения, называется методом К-гармонических средних (K-Harmonic Means, KHM) и показывает хорошие результаты сегментации для трех и более классов [74]. Еще одним вариантом модификации алгоритма К-средних является метод спектральной классификации (Spectral Classification, SC), основанный на применении собственных значений матрицы мер конвергенции, в качестве элементов

которой используются оценки относительной схожести каждой пары точек исходного изображения. Сама идея метода SC основывается на теории графов, где проблема кластеризации рассматривается как проблема разделения графов. С этой точки зрения, данные, имеющие форму графа подобия, должны быть разделены на подграфы таким образом, чтобы ребра среди и между подграфами имели бы наименьший и наибольший веса соответственно [75]. В целом метод SC в сочетании с различными приемами, такими как формирование различных производных изображения и модификаций метрики [76, 77], показывает более точные результаты сегментации в сравнении с классическим алгоритмом К-средних [78], однако является вычислительно более громоздким и требует использования различных математических допущений и приемов по снижению размерности анализируемого пространства, например, таких как низкоранговое матричное разложение [75–79]. Следует отметить, что при использовании кластерных методов в задаче сегментации РЛИ предварительная фильтрация, например, морфологическая обработка или фильтр Фроста, позволяют добиться более качественных результатов [69, 74].

1.3.3. Нарращивание областей

Алгоритмы с наращиванием областей основаны на предположении, что соседние элементы одного кластера должны обладать схожими характеристиками на исходном изображении. На первом этапе вручную либо автоматически выбирается элемент изображения, называемый точкой посева, после чего происходит сравнение ее характеристик с ближайшими соседями в рамках некоторого окна, определяемого алгоритмом. В случае выполнения некоторого критерия схожести, который, как правило, представляет собой минимум разности между признаком точки посева и некоторой функции от анализируемого элемента, соседние пиксели присоединяются к точке посева, и выполняется рост региона (метод Seeded Region Growing, SRG). Способ выбора конкретного критерия схожести существенно предопределяет качество сегментации и должен быть выбран с учетом свойств исходного изображения. После завершения роста региона выбирается другая точка посева, не принадлежащая к сформированному ранее кластеру [80]. Методы, основанные на обозначенном подходе, являются довольно быстрыми с точки зрения машинного

исполнения, поскольку вместо отдельных элементов изображения анализируются кластеры элементов [81, 82]. Помимо яркости, в рамках окна может быть произведен расчет других статистических характеристик, например, энтропии, что позволяет формировать кластеры с учетом текстуры изображения [83]. Сочетание алгоритмов наращивания областей с точками посева с другим методами сегментации, такими как SC и метод Оцу, обеспечивает точность классификации ПРЦ выше, чем 90 % [80, 84]. На практике используется вариант разностного метода SRG, при котором сегментируется алгебраическая разность двух изображений одной и той же сцены, что может быть использовано в задачах обнаружения изменений, например, оценки последствий землетрясений [85].

Применительно к РЛИ хорошие результаты сегментации дает вариация метода с учетом статистических характеристик формируемых кластеров – статистическое слияние регионов (Statistical Region Merging, SRM). В обозначенном алгоритме первоначально каждый элемент изображения формирует отдельный самостоятельный кластер, при этом выполняется построение графа каждого из элементов с использованием четырех ближайших соседей. Далее осуществляется сортировка граничных элементов на основе статистических данных в случае, если параметры распределения объединенных участков не отличаются от двух формирующих, то объединенный участок сохраняется как отдельный кластер [86]. Сам критерий схожести статистики распределений объединенных кластеров обуславливается двумя параметрами, один из которых отвечает за интенсивность подавления спекл-шума, второй – за степень детализации выходных данных [87]. Метод SRM хорошо зарекомендовал себя при сегментации мультиполяризационных РЛИ различных диапазонов, при этом отмечается его слабая чувствительность к спекл-шумам и достаточно высокая скорость обработки [88]. Использование метода в качестве инструмента бинаризации РЛИ на примере распознавания аквакультур показывает результаты с точностью выше, чем 85 % [89].

1.3.4. Выделение границ

Границы кластеров тесно связаны с понятием перепадов яркости на изображении, откуда берет свое начало группа методов сегментации на основе выделения границ. Поиск границ основан на оценивании усредненных значений яркости в рамках некоторого окна и дальнейшем сравнении

с пороговым значением, величина которого оценивается исходя из статистических свойств текущего фрагмента изображения [90]. Для формирования цельных участков на сегментированном изображении, наряду с классическими приемами по выделению границ на цифровом изображении применительно в задачах сегментации, должна быть решена проблема объединения полученных границ. Для решения этой задачи могут быть использованы морфологические фильтры [90] либо один из алгоритмов «водораздела» (watershed) [91, 92]. Процедура выполняется итерационно до тех пор, пока не будет достигнут минимум дисперсии по всем сформированным кластерам. В целом алгоритмы на основе выделения границ работают достаточно быстро и не требуют априорных сведений о статистических свойствах изображения, однако могут быть учтены посредством использования метода максимального правдоподобия для достижения более высокого качества сегментации РЛИ [92]. Они могут быть использованы в сочетании с другими методами сегментации, например, SRG, что позволяет получить низкую ошибку ложных срабатываний [90].

1.3.5. Модель активного контура

Метод модели активного контура (Active Contour Model, АСМ) применяется в задачах обнаружения областей на изображениях. Здесь вводится понятие функционала энергии, описывающей свойства плоской кривой, параметрически заданной на изображении. Процедура сегментации сводится к минимизации функционала энергии, за счет чего происходит деформация активного контура таким образом, чтобы он оптимальным образом соответствовал границам кластеров [93]. Функционал энергии, как правило, определяется двумя составляющими: внутренней энергией, определяемая количеством изгибов и степенью сжатия кривой, и внешней энергией, отвечающая за смещение кривой к границам кластеров и определяемая через меру несхожести внешнего и внутреннего фрагментов изображения. В классическом методе АСМ внешняя энергия рассчитывается как интеграл от результата перемножения некоторой функции активации с евклидовой метрикой, определенной на изображении, однако такой подход оказывается слишком чувствительным к спекл-шумам на РЛИ [94, 95]. Одним из способов модификации метода является замена классической метрики на логарифмическое отношение максимального правдоподобия [94–102], что

позволяет существенно снизить влияние шумов на результат сегментации. При этом, как правило, выдвигается предположение о том, что яркость элементов РЛИ распределена в соответствии с гамма-распределением [94], [97, 98, 101, 103], однако возможно применение распределений Вейбулла [99] и Гаусса [100]. В качестве альтернативных способов изменения метрики при расчете внешней энергии может быть использована дивергенция Йенсена, такой подход обеспечивает низкую частоту ложных срабатываний и демонстрирует точность сегментации различных типов подстилающей поверхности вплоть до 100% [104]. В качестве функции активации может быть использована радиальная базисная функция Гаусса [94, 105, 106] либо двумерная функция Хэвисайда [101, 103]. Сама процедура сегментации выполняется итерационно до тех пор, пока величина изменения функционала энергии не будет меньше некоторого заданного порогового значения. В задачах уменьшения влияния шума на результат сегментации возможен также вариант использования аддитивного метода АСМ, в этом случае на каждой итерации осуществляется расчет нормализованных внутриклассовых значений дисперсии либо энтропии внешних и внутренних регионов изображения, полученные значения используются как аргументы весовых коэффициентов функционала энергии [105, 107].

Итоговая форма контура, описываемого полученным функционалом энергии, должна удовлетворять уравнению Эйлера-Лагранжа, которое решается с использованием численных методов, что в общем случае является достаточно трудоемкой и медленной процедурой [94]. Ускорение процедуры обработки возможно за счет минимизации функционала энергии через функцию градиента по каждому из параметров [99, 100, 105, 106], матричное разложение [97, 108], метод установки уровня, построение многоступенчатой модели на основе отдельных сжатых изображений [101]. Метод, основанный на модели активных контуров, показывает надежные результаты сегментации на примере модельных и реальных РЛИ, а также обнаружения объектов на водной поверхности, например, кораблей по данным различных диапазонов с точностью 90% и выше [94, 95], нефтяных разливов [100, 107]. Построение функционала энергии с учетом дополнительных производных признаков изображения, таких как моменты изображений и вейвлет-преобразование, позволяет учесть текстуру изображения в ходе сегментации [108]. Предварительная пространственная фильтрация позволяет повысить точность сегментации [102, 108].

1.3.6. Скрытые марковские поля

Использование идеи марковских случайных полей (Random Markov Field, RMF) относится к области полуавтоматизированных методов классификации изображений, находящихся на промежуточной стадии между сегментацией и обучения с учителем. Наиболее естественным способом определения марковских случайных полей применительно к задаче сегментации изображений является представление последнего в виде неориентированного графа, причем в качестве вершин графа выступают элементы изображения, а ребра графа представляют собой связи элементов между собой. Процедура сегментации в данном случае отождествляется с разделением графа на подграфы в соответствии с некоторыми признаками, при этом в основе лежит, как правило, использование байесовского подхода [109]. Апостериорная вероятность будет определяться функцией правдоподобия, определяемой исходными данными, и априорной вероятностью, учитывающей ближайшее окружение элемента. Наилучшему результату разбиения графа будет соответствовать максимум апостериорной вероятности, либо, в соответствии с теоремой Хаммерсли-Клиффорда [110], минимум потенциальных функций распределения Гиббса, что позволяет перейти от апостериорной вероятности к апостериорной функции энергии графа, определяемой через два и более слагаемых. Количество слагаемых соответствует количеству элементов ближайшего окружения анализируемого пикселя РЛИ. Как правило, при использовании метода RMF ограничиваются четырьмя ближайшими соседями, что соответствует двум слагаемым в выражении для функции энергии [111], однако при анализе текстуры бывает удобно использовать девять ближайших соседей и более [112, 113]. Модифицированный алгоритм RMF позволяет использовать количество элементов окружения в роли адаптивного параметра [109]. Применительно к РЛИ сегментация с применением марковских случайных полей обладает рядом преимуществ, поскольку не требует предварительного подавления [111] спекл-шумов и в сочетании с вейвлет-преобразованиями может быть использована для учета текстуры отдельных фрагментов изображения [114, 115]. Следует отметить, что сегментация на основе марковских случайных полей является достаточно трудоемким методом, и для ускорения процедуры обработки по нахождению минимума функции энергии, как правило, используются различные дополнительные

приемы, например, метод градиентного спуска [111]. В целях оптимизации возможно выполнение сегментации в несколько этапов, соответствующих разной степени детальности для выражения функции энергии [112, 114]. Хороший результат по скорости получения результата может быть достигнут при использовании предварительной классификации без учителя, например, алгоритмом водораздела [116] либо наращиванием областей методом SRG [81, 117].

Несмотря на высокие требования к вычислительной технике, метод RMF показывает высокие результаты, превосходя по точности традиционные методы обучения без учителя [111]. Формируемые атрибутивные данные обладают высокой степенью однородности [109, 116], а для метода в целом характерно низкое значение ошибок пропуска и ложных срабатываний [112, 115]. Применение марковских случайных полей особенно эффективно при анализе текстур изображения [112, 115] и позволяет корректно сегментировать даже сравнительно тонкие детали схожих по яркостным признакам фрагментов РЛИ [114, 118]. В частности, показано успешное применение метода RMF на примере данных различных диапазонов в задаче классификации пяти и более типов подстилающей поверхности с точностью не хуже 90%. Также марковские случайные поля могут быть использованы при обработке мультиполяризационных данных, при этом связь между отдельными каналами многомерного изображения задается через корреляционные матрицы [81, 109].

1.3.7. Вывод по разделу 1.3

В большинстве случаев результаты классификации РЛИ без учителя оказываются менее точными в сравнении с алгоритмами, основанными на обучении. Достаточно надежные результаты могут быть получены только для кластеризации регионов с сильно различающейся эффективной поверхностью рассеивания, как, например, в задачах выделения гидрографических объектов на общем фоне изображения либо обнаружения различных целей на водной поверхности. В случае, когда яркостные свойства классифицируемых регионов слабо различаются, надежные результаты могут быть получены преимущественно для модельных изображений, в случае применения предлагаемых алгоритмов к реальным РЛИ значительная доля успешных испытаний соотносится скорее с удачным

выбором набора пороговых значений и различных параметров применяемых моделей сегментации, который не будет универсальным как для различных РСА-систем, так и для различных сцен, формируемых одной РСА-системой. Как правило, в реальных практических задачах полученные в ходе сегментации данные используются в качестве предварительной оценки структуры изображения с целью выбора дальнейшего метода классификации либо обнаружения уже с применением учителя. Тем не менее, сегментированные изображения в ряде случаев могут дополнять методики, основанные на обучении, например, метод опорных векторов [119]. Так, результат сегментации РЛИ кластерным методом SRM в сочетании с методом опорных векторов показывает возможность классификации различных типов растительности (более 10 классов) с точностью не хуже, чем 90 % [120, 121], а дополнительный расчет коэффициентов вейвлет-преобразования позволяет проводить кластеризацию с учетом не только яркостных, но и текстурных признаков [6]. Однако следует отметить, что формируемые в ходе алгоритмов без обучения области оказываются достаточно неоднородными и в большинстве случаев требуют применения морфологических фильтров и иных приемов улучшения РЛИ перед применением в качестве самостоятельной карты признаков. Также следует отметить затруднительную процедуру оценки точности методов сегментации РЛИ, в большинстве случаев оценка точности производится постфактум, визуально исходя из границ контуров реальных объектов.

1.4. Классические методы

Классические методы классификации изображений включают в себя группу параметрических алгоритмов с обучением, в основе которых лежит максимизация апостериорной вероятности принадлежности элементов изображения к конкретному классу либо минимизация рисков попадания в некорректные классы. Сами алгоритмы при условии, что плотности вероятностей распределений классов известны, в этом случае могут быть представлены в явном аналитическом виде, и, более того, представленные алгоритмы оказываются оптимальными [122], то есть вероятность ошибок будет наименьшей из возможных. Применительно к задачам обнаружения целей на РЛИ в качестве плотностей распределения вероятностей, как правило,

используется гамма-распределение, конкретные его параметры могут быть оценены на основе элементов обучающей выборки, однако в этом случае алгоритмы теряют свойство оптимальности, поскольку восстановление параметров возможно только с некоторой погрешностью. Приведенная группа методов представляет собой наиболее ранние алгоритмы классификации и распознавания изображений, однако до настоящего времени не теряют своей актуальности как в классической форме, так и в составе различных гибридных решений. Применительно к радиолокационным данным ДЗЗ чаще всего из этой категории алгоритмов применяется байесовский классификатор, линейный дискриминантный анализ и логистическая регрессия, а также во многом схожий в контексте формализации алгоритм постоянной вероятности ложных тревог.

1.4.1. Байесовский классификатор

Классический подход распознавания образов на изображении основан на непосредственном использовании байесовского классификатора [122], в основе которого лежит прямое использование теоремы Байеса и описание вероятностей распределения исходных данных. В задаче распознавания ПРЦ на РЛИ в качестве априорного закона распределения яркостей элементов чаще всего используется гамма-распределение [123–126]. Однако в ряде случаев, например, в случае предварительной пространственной фильтрации изображения [123], вероятностный закон для яркостей элементов изображения может быть заменен на нормальный, что позволяет несколько ускорить расчеты, сохраняя точность получаемых результатов [123, 127, 128]. Для уточнения априорного распределения вероятностей дополнительно может использоваться какой-либо из методов оценки меры схожести теоретического распределения и гистограммы РЛИ, например, расчет дивергенции [124]. В качестве метода оценки параметров байесовских моделей, как правило, применяется метод максимального правдоподобия [124, 126, 127], однако правомерными оказываются и иные подходы, например, минимизация дивергенции Кульбака–Лейблера [129, 130]. Полученная оценка позволяет минимизировать апостериорный риск по интересующему набору параметров неопределенности, что позволяет в конечном счете не только установить наличие либо отсутствие образа цели на РЛИ,

но и выполнять оценку значений ее координат, геометрических параметров и величины эффективной поверхности рассеивания [123, 131].

Алгоритм байесовского классификатора показывает высокую эффективность в задачах обнаружения различных целей по радиолокационным данным ДЗЗ. Названный подход демонстрирует точность выше 90 % в задачах обнаружения морских судов трех различных типов на водной поверхности по данным RADARSAT-2 [130] и объектов базы MSTAR [132]. Также байесовский классификатор успешно применяется в задаче обнаружения изменений по разновременным изображениям, в этом случае на предварительном этапе выполняется привязка и строится вспомогательная матрица, представляющая собой отношение исходных РЛИ. В этом случае плотность вероятности оказывается симметричной относительно отношения математических ожиданий исходных данных, что облегчает последующее применение теоремы Байеса [124].

Расширением реализации классического байесовского классификатора является Байесовская сеть (Bayesian network) – вероятностная графовая модель, состоящая из множества трех и более признаков и их вероятностных зависимостей, определяемых по теореме Байеса. Такой подход используется в задачах идентификации различных типов целей (от четырех и более) при анализе значительной совокупности признаков, включая текстурные, причем байесовская сеть позволяет не только оценить местоположение и характеристики цели, но и угол ее наблюдения [128, 133]. Следует отметить, что обозначенный алгоритм оказывается вычислительно ёмким, поэтому в качестве априорного распределения яркостей элементов изображения, как правило, используется нормальное распределение, а для оптимизации расчетной процедуры могут оказаться эффективными различные вспомогательные методы, например, Венгерский алгоритм [127]. Использование байесовской сети в качестве классификатора в задачах обнаружения образов целей на РЛИ позволяет достигнуть точности до 99 % на примере обнаружения объектов базы MSTAR [127].

Классический подход к распознаванию образов на РЛИ, основанный на теореме Байеса, может успешно сочетаться с различными приемами по снижению размерности. Особенно эффективно в этом плане проявляет себя низкоранговое матричное разложение, при использовании которого точность распознавания отдельных типов объектов базы MSTAR

достигает 99% [134], которое так же может использоваться как инструмент снижения размерности в задаче обнаружения изменений по полным сценам космоснимков [135]. Также широкое применение находит предварительное преобразование с помощью метода главных компонент [136–138] и выделение частотных признаков с использованием вейвлет-преобразования, позволяющее достигнуть точности распознавания до 95% и выше на примере реальных радиолокационных данных ДЗЗ [8, 9, 139]. Достаточно часто встречаются различные гибридные архитектуры, например, использование принципов байесовской классификации на этапе нахождения оптимальных «атомов» в методе разреженных представлений [140–142], демонстрируя точность, превышающую 97% на примере распознавания объектов базы MSTAR. Байесовский классификатор успешно применяется на этапе обучения свёрточных нейронных сетей, позволяя достигнуть точности распознавания целей по реальным РЛИ до 98% и выше без значительного углубления сети [125, 143, 144].

1.4.2. Дискриминантный анализ

Метод линейного дискриминантного анализа (Linear Discriminant Analysis, LDA) представляет собой алгоритм, принципиально не отличающийся от метода главных компонент. Построение пространства признаков выполняется в виде линейной комбинации исходных данных, причем направление новой оси подбирается таким образом, чтобы максимизировать разделимость между классами в соответствии с эталонными выборками [122]. Для нахождения коэффициентов перехода к новому пространству признаков чаще всего используется критерий Фишера, основанный на расчете матриц разброса внутри класса и между классами. Множественный дискриминантный анализ (Multiple Discriminant Analysis, MDA) представляет собой естественное обобщение линейного дискриминантного анализа, в этом случае пересчет происходит не на одну, а сразу на несколько новых координатных осей с учетом вышесказанных критериев. Зачастую для нахождения координат в новом пространстве признаков изображения эталонной выборки требуют существенной предварительной обработки [145], например, эквализация гистограмм, использование сглаживающих пространственных фильтров, а также предварительный перевод в частотную область с целью устранения сдвиговых эффектов образов [146]. Применительно к задачам

распознавания образов на РЛИ линейный и множественный дискриминантный анализ не применяются, однако могут быть успешно интегрированы с иными методами классификации с обучением, например, метод опорных векторов [145–147] и искусственные нейронные сети [148, 149].

1.4.3. Логистическая регрессия

Метод классификации, основанный на использовании логистической регрессии (Logistic Regression, LR), подобно байесовскому классификатору, основан на прогнозировании вероятности отнесения вектора признаков к тому или иному классу с помощью сравнения с логистической функцией, отклик которой принимает бинарные значения, что соответствует наличию либо отсутствию образа цели на изображении [150]. Конкретные значения коэффициентов регрессии определяются по параметрам обучающей выборки, для их последующей оценки, как правило, применяется метод максимального правдоподобия, градиентного спуска либо пошагового отбора [151, 152]. Метод может быть расширен на решение задачи о поиске целей различных типов (множественная логистическая регрессия (MLR)), в этом случае отклик логистической функции может принимать три и более значений. В частности, в задачах классификации мультиполяризационных данных ДЗЗ на восемь классов использованием метода MLR может быть достигнута точность до 90% в сочетании с низкими значениями ошибок ложного срабатывания [151]. Следует отметить, что в исходной форме метод логистической регрессии в задачах обнаружения целей на РЛИ используется достаточно редко, однако сравнительно часто применяется на последнем слое архитектуры искусственных нейронных сетей в качестве классификатора [40, 41, 153–157].

1.4.4. Постоянная вероятность ложных тревог

Постоянная вероятность ложных тревог (Constant false alarm rate, CFAR) представляет собой адаптивный алгоритм, применяемый в радиолокации. Принятый радиолокатором отраженный сигнал включает в себя как полезную составляющую, так и различные помехи, обусловленные как собственным шумом приемника, так и всевозможными внешними факторами. Алгоритм CFAR предназначен для оценки минимального порогового значения мощности, при превышении которого сигнал следует считать

относящимся к цели. При чрезмерно низком значении порога будет увеличиваться число ошибок ложного срабатывания, при высоком, напротив, количество ошибок ложного срабатывания будет сведено к минимуму, однако возрастет число ошибок пропуска цели. В большинстве задач обнаружения полезного радиолокационного сигнала при проектировании РЛС величина порогового значения устанавливается исходя из требований к вероятности возникновения ошибок ложных тревог. В подавляющем большинстве реальных ситуаций уровень шума не является постоянной величиной и является функцией пространственных и, в ряде случаев, временных координат, в этом случае пороговое значение должно изменяться по ходу выполнения алгоритма поиска цели для поддержания постоянной ошибки ложных тревог [158]. Применительно к задачам обработки РЛИ в этом смысле формализация алгоритма CFAR подобна классическому подходу, поскольку расчет величины необходимого порога осуществляется исходя из анализа статистических свойств радиолокационных изображений и последующего применения аппарата теории вероятности.

В случае использования алгоритма CFAR по отношению к двумерному сигналу его классическая форма требует ряда модификаций, для решения этой задачи используется два подхода. Первый подход, как правило, основан на предварительном выделении границ участков изображения, в качестве метода может быть использован оператор Собеля [159–161], расчет градиента вдоль направлений азимута и дальности [162], различные методы предварительной сегментации [163]. Этот этап позволяет выделить потенциальные области, соответствующие положению образа цели и упростить дальнейшие вычисления, однако может быть заменен на разбиение исходного изображения на некоторое количество фрагментов и последующего расчета в рамках каждого из них [164]. На следующем этапе на границах полученных регионов находится условная плотность вероятности для двух окрестностей, расположенных по разные стороны, и с ее помощью находится оценка порогового значения [159]. За исходное распределение яркостей элементов РЛИ в этом случае берется либо гамма-распределение [159, 160], либо некое его обобщенное представление, например, G_0 [165] или GFD [164, 166]. Для оценки параметров используемых распределений дополнительно могут применяться различные методы, например, метод Парзенковского окна

[161] или метод логарифмических кумулянт [164]. Далее задается величина вероятности ошибки ложного срабатывания, как правило, несколько сотых долей процента [159, 162, 165], и на основе этого значения выполняется расчет величин порогового значения [159]. На заключительном этапе с целью упрощения анализа результатов может применяться морфологическая фильтрация [159, 160, 163], кластеризация [165] и медианная фильтрация [160]. Полученный алгоритм показывает высокую эффективность в задачах обнаружения различных целей, таких как объекты базы MSTAR [160, 165] и обнаружение морских судов на водной поверхности [161, 162] даже на детальных РЛИ, показывая добротность (отношение общего числа корректно найденных целей к сумме ложных срабатываний и действительному количеству целей), приближающуюся к 100 % при ошибке ложного срабатывания, составляющей 0,01 % [160]. Показано, что с ростом размера областей, в рамках которых происходит подсчет статистики РЛИ, увеличивается оценка порогового значения [159], поэтому алгоритм может быть использован даже для нахождения слабоконтрастных целей.

Второй подход адаптации к двумерным сигналам основан на применении двухпараметрического метода CFAR, основанного на расчете двух статистических параметров в рамках двух concentрических окон элемента изображения, причем размер малого окна соотносится с характерным размером образа цели. Первый параметр представляет собой нормализованное значение яркости элемента, а второй параметр – разность либо отношение дисперсий элементов в пределах concentрических окон [167–169]. В этом случае работа алгоритма основывается на том факте, что значение яркости элементов цели превышает значения элементов яркости окружающих элементов. После получения оценок, как правило, применяется показатель степени Хёрста [170], позволяющий осуществлять поиск образов целей по всей области изображения как единого целого [167, 169]. Задание необходимого уровня вероятности возникновения ошибок ложного срабатывания осуществляется через формирование кривой ошибок. На завершающем этапе для устранения разрывов и упрощения последующей интерпретации результата может применяться обработка морфологическим фильтром [169]. Приведенная схема алгоритма CFAR позволяет выполнять поиск целей на изображении с точностью до 95 % и выше, что

показано на примере объектов базы MSTAR [167,169], а также осуществлять предварительный анализ точности алгоритма. Следует отметить, что в такой реализации алгоритма CFAR предложение об исходном распределении значений яркости элементов изображения задается как нормальное, поскольку распределения более сложной формы требуют существенного увеличения времени обработки.

1.4.5. Вывод по разделу 1.4

Несмотря на сравнительно простую формализацию, байесовские классификаторы и иные методы классификации, основанные на минимизации апостериорных рисков, в ряде случаев могут обучаться достаточно эффективно и зачастую по точности получаемых результатов могут составить конкуренцию различным методам глубоко обучения, таким как искусственные нейронные сети. Классические подходы распознавания по радиолокационным данным ДЗЗ, являются в значительной мере робастными, что особенно актуально по отношению к РЛИ, неотъемлемым свойством которого является присутствие мультипликативного спекл-шума. Большинство работ, основанных на использовании этой группы методов, содержит разделы, посвященные дополнительным исследованиям их точности при вариации параметров целей и шумов, что позволяет делать выводы об оценке алгоритмов распознавания без длительной их апробации, а также целесообразности их применения в различных ситуациях. Приведенные методы не требуют значительных вычислительных ресурсов и в большинстве случаев дополнительных процедур оптимизации расчетов, что позволяет решать задачу поиска целей на РЛИ достаточно быстро. Однако в настоящий момент в научном сообществе представлено сравнительно немного работ, основанных на использовании исключительно классических подходов, за исключением алгоритма CFAR, что позволяет сделать вывод о недостаточной тщательности проведенных исследований по возможности их применения, а также потенциальных перспективах использования.

1.5. Классификация с обучением

В основе методов классификации изображений с учителем лежит использование обучающих выборок – наборов эталонных фрагментов, относительно которых достоверно известен тип определяемого класса.

Процедура распознавания заключается в сопоставлении признаков (яркостных, текстурных, геометрических и иных) анализируемых элементов изображения и эталонов, а решение принимается в пользу того класса, для которого мера схожести является наибольшей. Наиболее простой непараметрической реализацией классификации с обучением является использование взаимной корреляционной функции.

1.5.1. Взаимная корреляционная функция

Несмотря на то, что в области ДЗЗ взаимная корреляционная функция (cross-correlation) широко используется в задачах автоматизированной геопривязки космоснимков [171–175], в ряде случаев она может выступать как один из простейших методов обнаружения цели заданного вида на РЛИ. Если на анализируемом изображении присутствует фрагмент, подобный эталону, отклик взаимной корреляционной функции будет содержать характерный максимум, который будет зависеть от степени сходства фрагмента с эталонным изображением [176]. Таким образом, в задачах поиска ПРЦ на РЛИ необходимо произвести расчет взаимной корреляционной функции для всех возможных эталонов, при этом истинному типу цели будет соответствовать эталон того класса, для которого максимум взаимной корреляционной функции окажется наибольшим.

Как следует из описания, использование взаимной корреляционной функции как метода распознавания образов возможен только для обнаружения объектов заданной формы и размера. В случае, если эти параметры заранее неизвестны (например, задачи классификации РЛИ, либо обнаружение вырубок и застроенных территорий) отклик корреляционной функции не даст выраженного максимума. При использовании корреляционного метода вероятность правильного распознавания типа целей прямо пропорциональна ее размеру, таким образом, метод является пригодным только в том случае, если эталоны для различных типов целей могут быть формализованы помимо яркостных характеристик с использованием иных, не связанных с пространственными размерами, параметров, например, структуры или текстуры изображений [177]. Для метода характерна существенная вычислительная сложность, растущая пропорционально квадрату исходного РЛИ [178]. Тем не менее, в задачах распознавания

образов на радиолокационных данных ДЗЗ метод, основанный на использовании взаимной корреляционной функции, обладает рядом преимуществ, в частности, он практически не чувствителен к отношению сигнал-шум и позволяет детектировать сравнительно низкоконтрастные объекты [179], кроме того, в ряде работ отмечается достаточно низкая частота ложных срабатываний обозначенного метода [178, 179], а сочетание с приемами по переходу в пространство признаков с использованием метода независимых компонент позволяет достигнуть точности распознавания до 90 % и выше [45].

1.5.2. Расстояние Махаланобиса

Традиционные подходы к процедуре классификации с обучением ассоциированы с непосредственным переходом в пространство признаков, и решение для каждой из ПРЦ принимается в пользу того класса, для которого некоторая мера между вектором наблюдаемых данных и положением усредненных характеристик эталона в пространстве признаков принимает наименьшее значение. Существует большое количество способов выбора метрик для оценки этой меры [180]. Одним из примеров такой метрики является расстояние Махаланобиса [181], представляющее собой обобщающее понятие евклидовой метрики, в котором осуществляется учет корреляций между случайными величинами.

Метод, основанный на расчете расстояния Махаланобиса, показывает достоверные результаты с точностью до 90 % при обнаружении изменений на местности произвольных геометрической форм и размеров в таких задачах, как оценка последствий землетрясений и разлива нефти на морской поверхности на примере фрагментов космоснимков, полученных с применением технологии РСА в различных диапазонах [182, 183]. Отмечается низкое значение ошибок ложного срабатывания и пусков целей, кроме того, метод успешно применяется в задачах классификации различных типов подстилающих поверхностей, обладающих схожими характеристиками, например, в задаче классификации ледовой поверхности [184], причем расчетные процедуры выполняются сравнительно быстро и не требуют специальных решений по оптимизации вычислений [182].

1.5.3. Метод k -ближайших соседей

В методе k -ближайших соседей (k -Nearest Neighbors, kNN) объекту присваивается тот класс, который является наиболее распространенным среди k соседей данного элемента, классы которых уже известны на основе обучающей выборки [185]. Выбор конкретного значения параметра k является самостоятельной процедурой, требующей отдельных исследований, поскольку его занижение может привести к росту ошибок пропуска, а чрезмерное его увеличение снижает четкость разделения между границами классов. Как правило, в методе kNN используется нормализация различного типа, например, минимакс-нормализация или Z -нормализация, что позволяет избежать зависимости от различий в ширине диапазонов атрибутивных признаков. Метод является непараметрическим, что подразумевает отказ от прямого рассмотрения статистических свойств анализируемого РЛИ. Метод k -ближайших соседей является примером одного из наиболее простых классификаторов с учителем как в плане технической реализации, так и с точки зрения потребляемых временных ресурсов, тем не менее, он показывает результаты распознавания, как правило, с точностью не хуже, чем 90% на примере задачи обнаружения объектов базы MSTAR [30, 186, 187].

1.5.4. Метод опорных векторов

В задачах распознавания образов практика перехода из пространства элементов в пространство признаков оказывается полностью оправданной, однако для классификации образов, обладающих схожими характеристиками, бывает целесообразно искусственно увеличить размерность пространства признаков таким образом, чтобы стало возможным адекватно разделить схожие классы, т.е. провести разделяющую их гиперплоскость. Эта идея лежит в основе метода опорных векторов (Support Vector Machines, SVM) [188], в котором увеличение размерности пространства признаков осуществляется с помощью специального преобразования, определяемого функцией ядра классификатора. Существует множество распространенных вариантов для выбора функции ядра, например, радиальная базисная функция Гаусса [140, 189, 190], полиномиальная [36, 190], линейная [190] и другие. Первоначально метод предполагал формирование

линейных разделяющих гиперплоскостей, однако позже появились его различные обобщения в виде нелинейных гиперплоскостей [191] и метода релевантных векторов [192,193], позволяющие более эффективно выполнять оценку вероятности принадлежности элемента к тому или иному классу. После построения серии оптимальных разделяющих гиперплоскостей в соответствии с эталонной выборкой элементы РЛИ могут быть успешно соотнесены со «своими» классами.

Метод опорных векторов позволяет достигнуть точности 90 % и выше в задачах распознавания объектов базы MSTAR [36, 37, 190, 194] в сочетании со сравнительно низким уровнем ошибок пропуска цели [36, 39, 134, 140, 190, 195]. Метод опорных векторов успешно используется в сочетании с различными приемами преобразованию пространства признаков, такими как метод главных компонент [36, 37] и метод независимых компонент [44], неотрицательного матричного разложения векторов признаков обучающей выборки (NMF) [134], а также выделению дополнительных дешифровочных признаков с помощью Фурье-преобразования [194] и нахождения центральных моментов изображения [119, 190].

Наиболее точные результаты достигнуты с применением гибридной технологии с применением классических подходов, таких как байесовский классификатор [134, 140, 145, 146, 195] и дискриминантный анализ [147], причем данный подход является в ряде случаев единственно возможным решением и зачастую показывает результаты более точные, чем использование искусственных нейронных сетей [36, 189, 193]. Однако метод обладает достаточно низкой скоростью обучения, кроме того, существуют повышенные требования к вычислительным ресурсам при использовании большого количества признаков, особенно в случае нелинейной гиперплоскости. Некоторого ускорения расчетной процедуры можно достичь, используя низкоранговое матричное разложение [48, 49, 51]. Точность классификации РЛИ возрастает обратно пропорционально количеству распознаваемых классов [39, 194], поэтому использование метода SVM не является универсальным решением. Отдельно следует отметить необходимость предварительного анализа исходных данных, необходимых для грамотного выбора адекватных параметров ядра классификатора [39, 193], что полностью предопределяет результаты работы алгоритма.

1.5.5. Метод разреженных представлений

Для снижения размерности исходных данных используется метод разреженного представления (Sparse Representation, SR), в котором произвольный вектор признаков представляется в виде взвешенной суммы векторов признаков эталонной выборки («словарь»), большинство компонент которых будут иметь нулевой либо почти нулевой коэффициент, за счет чего и достигается эффект разреженности. В качестве таких ненулевых компонент («атомов») могут выступать границы объектов, текстурные особенности и иные признаки, значительно отличающиеся друг от друга. Сам эффект разрежения размерности достигается за счет минимизации внутриклассового разброса по квадрату некоторой нормы, причем полученные таким способом «атомы» будут идеально соотноситься с образцами, относящимися к тому же классу, по эталону которого выполнена минимизация. Сама процедура минимизации является NP-жесткой, и зачастую ее решение требует значительных самостоятельных исследований [3, 29, 196]. Существуют разные методы решения задачи минимизации, в качестве примера можно привести метод случайной проекции [196, 197] либо метод согласованного преследования [198, 199].

Метод разреженных представлений на примере обнаружения объектов базы MSTAR демонстрирует точность распознавания, превышающую 90 % [200], в сочетании со сравнительно высокой скоростью обработки, причем в ряде случаев оказываясь точнее, чем иные методы классификации с учителем, например, метод опорных векторов [11, 196] и метод k ближайших соседей [30, 186, 201]. Как и для метода SVM, точность классификации растет с уменьшением количества распознаваемых классов [200]. Особую эффективность метод разреженных представлений демонстрирует в сочетании с другими приемами, такими как предварительный перевод изображения в частотную область [11] и снижение размерности пространства признаков с использованием низкорангового матричного разложения [50]. Метод успешно применяется в задаче многопоточной классификации для обработки серии РЛИ с различным пространственным разрешением [202, 203].

1.5.6. Дерево решений

Еще один способ классификации изображений с учителем основан на поэтапном разбиении пространства признаков на непересекающиеся области. Такой подход называется деревом решений, при этом каждому узлу дерева соответствует определенный атрибут, в зависимости от значения которого и происходит этап классификации [204]. Применительно к задачам распознавания образов по РЛИ чаще используется метод под названием «случайный лес» (Random Forest, RF), основанный на использовании большого ансамбля деревьев решений. В этом методе генерируется случайная дополнительная выборка из обучающих векторов, для которых строится решающее дерево, причем для создания очередного узла выбирается некоторое количество случайно однообразных признаков. Критерий выбора наилучших из признаков может быть различным, например, критерий Джини или критерий прироста информации. Решающее дерево строится до полного исчерпывания дополнительной выборки и, в отличие от классического дерева решений, не подлежит процедуре отсечения ветвей. Сам процесс классификации проводится путем голосования, при этом побеждает тот класс, за который проголосовало наибольшее число решающих деревьев [205].

Метод «случайный лес» показывает высокую эффективность в задачах классификации полного кадра РЛИ на примере данных различных диапазонов, в особенности при использовании мультиполяризационных данных [38, 206, 210]. Точность классификации при этом составляет 70 % и выше для различных типов агрокультур и 90 % и выше для антропогенных объектов [206, 207, 209, 211].

В общем случае отмечаются высокая эффективность метода «случайный лес» в задачах классификации данных с большим количеством признаков, при этом возможна достоверная классификация в случае присутствия в кадре десяти и более различных классов [209, 211]. Однако метод требует достаточно большого объема памяти для хранения формируемых моделей, и как, следствие, обладает низкой вычислительной мощностью [34, 38]. Широко применяется гибридная технология «вращение леса», основанная на сочетании метода RF с методом главных компонент, что позволяет, с одной стороны, снизить размерность исходных данных и ускорить процесс обработки, с другой стороны, несколько повысить точность классификации [38, 212].

1.5.7. Модель ASC

Несколько обособленное положение в распознавании образов по радиолокационным данным ДЗЗ занимает подход, основанный на предварительном моделировании двумерных образов распознаваемых целей с учетом всех параметров съемки, а также геометрических и яркостных свойств конкретного типа (модель Attribute Scattering Centre, ASC) [3]. Полученные модели выполняют роль элементов обучающей выборки, в дальнейшем выполняется их сопоставление с реальными фрагментами РЛИ тем или иным методом. В качестве классификатора могут быть использованы классические методы распознавания, такие как байесовский подход [213, 214], метод опорных векторов [213, 215] и разреженных представлений [213, 215–217]. Для поиска соответствий моделей ASC с фрагментами РЛИ возможно использование менее традиционных приемов, например, применение венгерского алгоритма за счет матричной интерпретации исходных данных [218, 219]. Применение моделей ASC в ряде случаев демонстрирует более точные результаты по сравнению с искусственными нейронными сетями [215]. Алгоритмы распознавания целей, основанные на применении моделей ASC, показывают точность классификации выше, чем 95 %, на примере задач обнаружения объектов базы MSTAR [215, 216, 219] при слабой чувствительности метода к пространственному разрешению итоговой модели [219] и возможности обработки мультиполяризационных данных [214]. Однако следует отметить, что такой способ классификации изображений достаточно трудоемкий, поскольку требует, как полной априорной информации о свойствах распознаваемых классов и параметров съемочной аппаратуры, которые зачастую неизвестны в полном объеме, так и разметки области интереса на самом РЛИ. Дополнительно к обозначенным моментам при формировании модели ASC необходим учет окружения цели, ее текстуры, эффекта анизотропии и возможного появления радиолокационных теней, [214, 213]. Распознавание образов с применением моделей ASC подразумевает обработку матриц большого размера, и оптимизация этой процедуры требует самостоятельных исследований, в качестве примера можно привести применение квази-ньютонских методов [213].

1.5.8. Выводы по разделу 1.5

Анализ работ, посвященных применению различных методов обучения с учителем в задачах распознавания и классификации РЛИ, показывает, что существует большое количество разнообразных алгоритмов, основанных на использовании эталонных выборок, как параметрических, так и непараметрических. При использовании любого из них в задачах распознавания образов на РЛИ возникает необходимость выбора между скоростью (как обработки, так и обучения) и точностью получаемых результатов. Наиболее качественные результаты классификации и распознавания могут быть получены с использованием методов опорных векторов и моделей ASC, причем в ряде случаев получаемые с их помощью результаты превосходят искусственные нейронные сети [36, 189, 193, 215]. Однако оба этих метода являются не только вычислительно трудоёмкими, но и требующими существенных временных затрат как на подготовку исходных данных, так и на решение вопросов, связанных с оптимизацией вычислений. Кроме того, в задачах классификации РЛИ точность метода опорных векторов обратно пропорциональна количеству распознаваемых классов [39], [194]. При работе с десятью и более классами достаточно эффективно проявляет себя метод «случайный лес», однако и его применение требует значительных вычислительных ресурсов.

1.6. Глубокое обучение

Общие идеи методов глубокого обучения основаны на моделировании высокоуровневых абстракций в противовес алгоритмам, ориентированным на конкретные узкоспециализированные задачи. Несмотря на то, что значительная часть алгоритмов этой группы методов была разработана еще в 70-ые годы прошлого века, значительная интеграция подходов глубокого обучения в процесс распознавания образов начала происходить только с середины 00-ых годов XXI века, что обусловлено, в первую очередь, существенным ростом вычислительных мощностей этого времени. Основным преимуществом использования методов глубокого обучения в задачах распознавания образов является их сквозной характер, включающий в себя обнаружение признаков, их описание и дальнейшее соотнесение с имеющейся иерархической структурой. Применительно к задачам обработки РЛИ в качестве глубоких методов чаще всего используются искусственные нейронные сети.

Искусственная нейронная сеть (ИНС) представляет собой математическую модель в виде программно-аппаратного воплощения, отображающую принципы сети нервных клеток живых организмов. Традиционные ИНС формализованы в виде системы объединенных искусственных нейронов, каждый из которых задействован только в обработке и формировании входящего и исходящего на него сигналов. В контексте ИНС принято выделять понятие ее обучения в противоположность общепринятым методам программирования, при этом процедура обучения заключается в нахождении весовых коэффициентов между отдельными нейронами. Такой подход позволяет выполнять существенное обобщение полученных результатов, что позволяет находить верное решение даже в условиях неполноты анализируемых данных. Применительно к задаче распознавания образов на изображениях, как правило, применяются свёрточные нейронные сети, относящиеся к алгоритмам обучения с учителем и основанные на использовании процедуры свёртки [220].

1.6.1. Свёрточные нейронные сети

В основе свёрточных нейронных сетей (Convolutional Neural Network, CNN) лежит идея чередования двух типов слоёв: свёрточных слоёв (Сслоев) и субдискредитирующих слоев (S-слоев), при этом на вход каждого из нейронов подается лишь определенный фрагмент исходного изображения, что позволяет сохранить топологию изображения внутри архитектуры сети. Обозначенные фрагменты изображения поэлементно перемножаются на ядро свертки, при этом полученный результат суммируется и записывается в соответствующую позицию выходного изображения. Такой подход позволяет сохранять инвариантность процедуры распознавания относительно операций сдвига, поворота и масштабирования, позволяя выявлять все более крупные и обобщенные структуры изображения. Концепция разделяемых весов в CNN-сетях предполагает использование ограниченного набора весов для существенного количества связей, что позволяет, с одной стороны, снизить требования к вычислительным ресурсам, с другой, уменьшить количество настраиваемых параметров. Тем не менее, возможен подход, при котором управление весами осуществляется с предшествующих уровней, за счет чего устанавливаются дополнительные связи в архитектуре сети, позволяющие добиться

точности распознавания до 99% [221]. Субдискретизация слоев заключается в уменьшении пространственной размерности изображения по мере углубления сети, а чередование слоев обеспечивает формирование карты признаков, полученной на основе атрибутивных данных предыдущего слоя, за счет чего достигается процедура распознавания сложных иерархических связей. В качестве метода вычисления градиента, используемого при обновлении весов перцептрона, как правило, используется метод обратного распространения ошибки [90, 222], функция активации нейрона в общем случае может быть произвольной, однако чаще всего используются нелинейные функции, например, функция гиперболического тангенса или радиальная базисная функция [223].

Использование свёрточных нейронных сетей в задачах распознавания образов позволяет получить результаты куда более достоверные в сравнении с традиционными методами обучения с учителем, в частности, на примере обнаружения объектов базы MSTAR на отдельных объектах точность достигает 96% и выше [221–227]. Основным фактором возникновения ошибок классификации по-прежнему является наличие спекл-шума на РЛИ, в связи с чем для достижения наилучших результатов требуется предварительная пространственная фильтрация, с использованием, например, фильтра Ли и фильтра Фроста [226, 228]. В отличие от традиционных методов обучения с учителем, основанных на единственном целевом изображении, ИНС позволяют объединять РЛИ, полученные с различных ракурсов [229], при этом каждый угол обзора соответствует отдельному входу на нейронную сеть, а уже в ходе обучения выполняется объединение в единую карту признаков. Для повышения точности распознавания возможна модификация традиционных свёрточных нейронных сетей, например, добавление перцептронов с дополнительными слоями [230], а также сочетание процесса обучения с иными, более традиционными подходами к распознаванию образов, что позволяет улучшить разделимость классов. Это могут быть как методы без учителя [231–233], так и с учителем, например, метод опорных векторов [224, 234–236] либо модель ASC [237].

Однако при использовании любых вариаций метода CNN отмечается значительное время, требуемое на сам процесс обучения нейронной сети, что исключает возможность применения свёрточных нейронных сетей

в режиме реального времени. Существуют разные подходы, позволяющие несколько ускорить процесс распознавания без существенных потерь точности, наиболее распространённый из них основан на дополнительном сжатии субдискредитирующих слоев [228, 238, 239]. В частности, в [238] показано, что сжатие S-слоев практически в 100 раз приводит к снижению точности распознавания не более, чем на 1 %, а производительность увеличивается почти в три раза. Еще одним приемом по ускорению процедуры обучения является уменьшение количества свёрточных слоев сети [225, 227, 228], что также дополнительно позволяет избежать эффектов переобучения сети. Наконец, могут оказаться полезными приемы, основанные на уменьшении размерности пространства признаков, таких как низкоранговое матричное разложение [227, 240] и адаптация функции потерь через линейный дискриминантный анализ [231].

Серьезной проблемой, возникающей при использовании свёрточных нейронных сетей, является недостаточный объем обучающей выборки, что приводит к переобучению сети и дальнейшему снижению ее эффективности при работе с реальными изображениями. Для увеличения обучающей выборки применяются различные подходы, например, использование тестовых изображений с наложенным спекл-шумом [226, 241], расширение обучающей выборки за счет изображений земной поверхности, полученных в оптическом диапазоне [234, 242–245]. Еще одним методом увеличения обучающей выборки для метода CNN является использование генеративно-сопоставительных нейронных сетей (Generative Adversarial Network, GAN), основанных на совместном использовании двух типов архитектуры: сети G , отвечающей за формирование эталонных изображений на основании имеющейся выборки, и сети D , предназначенной для выявления таких изображений. Таким образом, состязательный эффект позволяет нарастить исходную выборку до необходимого объема в соответствии с заложенными критериями [246]. Наиболее удачное применение метода GAN заключается в наращивании выборки за счет добавления изображений, соответствующих разным углам обзора [247], а также преобразованию изображений оптического диапазона в радиолокационный [248]. Искусственное увеличение обучающей выборки позволяет избежать переобучения и улучшить точность классификации, однако требует значительных дополнительных временных затрат.

1.6.2. Автокодировщики

Автокодировщики представляют собой группу искусственных нейронных сетей, использующих подход обучения без учителя. Базовая архитектура автокодировщика содержит три слоя: входной (энкодер), промежуточный и выходной (декодер), причем количество нейронов в энкодере и декодере должны совпадать. На промежуточный слой при этом накладывается ряд ограничений, как правило, заключающихся либо в снижении его размерности, например, с помощью Фурье- или вейвлет-преобразований [249], либо разреженности активации, за счет чего при восстановлении данных, поступающих с декодера, достигается обобщение исходных данных. Как следует из описания принципа работы автокодировщиков, их основное предназначение заключается в снижении размерности признаков, причем зачастую такой подход оказывается более эффективным в сравнении с традиционными методами, такими как метод главных компонент и марковских случайных полей [250]. В задачах классификации РЛИ автокодировщики, как правило, используются в качестве элемента архитектуры основной свёрточной нейронной сети в случае значительной ее глубины, позволяя сократить временные ресурсы, необходимые для ее достаточного обучения [251, 252]. Подобно методам сегментации изображений, автокодировщики могут быть использованы как самостоятельный инструмент для нахождения изменений по разновременным РЛИ, однако в этом случае для снижения ошибок ложного срабатывания, вызванных присутствием спекл-шума на изображениях, метод требует дополнительных модификаций. В качестве примера можно привести использование линейного дискриминанта Фишера в качестве разрешающего правила [149], объединение с методом кластеризации К-средних [253] или С-средних [254].

1.6.3. Ограниченная машина Больцмана

Машина Больцмана (Boltzmann Machine, BM) является разновидностью искусственной нейронной сети, позволяющей определять распределение вероятностей на исходных данных и, подобно автокодировщикам, реализующей подход обучения без учителя [255]. Базовая архитектура состоит из двух слоев, скрытого и видимого, причем в целях уменьшения ресурсов на обучение допустимы только межслойные нейронные связи (ограниченная машина Больцмана, Restricted Boltzmann Machine, RBM),

а скрытый слой машины содержит в себе признаки, которые и устанавливаются в процессе обучения [256]. Вероятность активации каждого из нейронов определяется через функцию Больцмана, распределение значений нейронов видимого слоя в задачах, связанных с обработкой РЛИ, как правило, задается распределением Гаусса или, в случае мультиполяризационных данных – Уишарта [255, 257]. В начальный момент времени состояние нейронов соответствует входному распределению данных, а далее ищется состояние сети, соответствующее минимуму энергии (тепловой шум в терминологии архитектуры сети), причем на низких температурах для достижения наилучшего решения приходится большее число итераций. Как и в случае с автокодировщиками, в задачах распознавания образов по РЛИ ограниченные машины Больцмана применяются на этапе предварительного обучения основной нейронной сети, либо в качестве одного из формирующих каскадов глубокой сети доверия [255, 257], Метод RBM может использоваться самостоятельно в задачах обнаружения изменений по разновременным космоснимкам [258] либо в сочетании с другими методами глубокого обучения, например, AbaBoost [156].

1.6.4. Глубокая сеть доверия

Глубокая сеть доверия (Deep Belief Network, DBN) представляет собой объединение нескольких каскадов сетей, основанных на обучении без учителя, в роли которых выступают автокодировщики, либо ограниченные машины Больцмана [154, 257, 259–261]. Такой тип сети содержит в себе несколько скрытых слоев, причем допустимы только межслойные нейронные связи. Обучение реализуется послойно (алгоритм жадного обучения), в ходе расчета весовых коэффициентов используется метод обратного распространения ошибки в сочетании с контрастной дивергенцией (CD). Такой подход позволяет более точно настраивать веса, с учетом различных особенностей образа на РЛИ, вызванных вариацией угла обзора [3]. Как правило, для достижения достаточной точности используется три или четыре скрытых слоя глубокой сети доверия [153, 259, 260, 262, 263]. Полученная архитектура может применяться самостоятельно для сегментации РЛИ, например, в задачах выявления изменений [154, 257, 259, 261], выступать в роли предобучающего элемента перед применением свёрточной нейронной сети (глубокая свёрточная нейронная сеть) [260], применяться

на последнем слое функции softmax, основанной на методе множественной логистической регрессии [153–155].

На сегодняшний день метод DBN является наиболее мощным решением в задачах сегментации РЛИ, демонстрируя на отдельных типах объектов земной поверхности точность распознавания, приближающуюся к 100% [154, 257, 261, 263]. Однако, несмотря на гибкость и впечатляющие возможности обобщения в условиях существенного искажения исходных образов, общим недостатком глубоких сетей доверия является достаточно трудоемкий процесс обучения, потребляющий существенные вычислительные и временные ресурсы [259], а также необходимость разработки дополнительных алгоритмов, учитывающих всевозможную специфику используемых данных. В частности, предварительная нечеткая сегментация [154, 259, 261], морфологическая обработка [259, 261] и пространственная фильтрация, например, управляющим фильтром [153], позволяют как снизить размерность входных данных, так и уменьшить вероятность неверной их интерпретации в следствие спекл-шума.

1.6.5. Рекуррентные нейронные сети

Рекуррентные нейронные сети (Recurrent Neural Network, RNN) представляют собой тип ИНС, учитывающий инерционность входных данных. При этом выход каждого из нейронов определяется результатом предшествующих вычислений, а скрытый слой такой сети может быть интерпретирован как запоминание результатов вычислений некоторого количества предшествующих шагов. Нахождение весовых коэффициентов основано на вариации метода обратного распространения ошибки ВРТТ, а общее количество скрытых слоев определяется количеством итераций, заложенных в сети. При этом параметры вычислений остаются идентичными для каждого из слоев, что позволяет несколько сократить требования к вычислительным ресурсам. Функция активации может быть произвольной нелинейной функцией, например, сигмовидной функцией или функцией гиперболического тангенса [255].

Несмотря на то, что наиболее распространённым использованием рекуррентных нейронных сетей, является анализ временных последовательностей, в последние годы все чаще встречаются работы по их применению в задачах распознавания РЛИ. В частности, метод RNN показал себя

как наиболее универсальный способ выявления закономерностей на РЛИ даже высокого пространственного разрешения, позволяющий сегментировать с точностью более 90 % даже такие анизотропные объекты, как дорожная сеть и сооружения [264]. Архитектура рекуррентных нейронных сетей может сочетаться с автокодировщиком, и тогда полученная модель выступает в роли инструмента сегментации РЛИ [264], либо со свёрточными нейронными сетями и сетями softmax [265, 266], а также иными методами обучения с учителем, например, методами разреженных представлений [267]. В случае применения подхода, основанного на обучении с учителем, высокая степень возможности обобщения исходных данных позволяет достичь точности распознавания на отдельных классах до 99 % [265], а универсальный набор параметров на различных итерациях сети RNN позволяет достичь сходимости в расчете весовых коэффициентов за сравнительно небольшое время по отношению к классическому методу CNN.

В литературе можно встретить и иные типы архитектур ИНН, используемых для классификации и распознавания образов, например, случайные нейронные сети (RnNN), остаточные нейронные сети (ResNet), сети радиально-базисных функций (RBF), глубокие каскадные сети на основе распределения Уишарта (W-DSN) и иные [255]. Все эти типы ИНН используются либо в сочетании со свёрточными нейронными сетями, либо с иными методами обучения с учителем, образуя различные гибридные архитектуры и направленные либо на сжатие размерности данных и последующее ускорения процедуры обучения, либо на учет ряда специфических особенностей, анализируемых РЛИ.

1.6.6. AdaBoost

AdaBoost представляет собой адаптивный мета-алгоритм машинного обучения, основанный на совместном применении нескольких алгоритмов слабой классификации. В качестве таких алгоритмов в задачах обработки РЛИ чаще всего выступают как классические методы обучения с учителем, например, метод максимального правдоподобия, метод минимального расстояния, метод k ближайших соседей, метод опорных векторов, «вращение леса» [40, 268–270], так и ИНС, такие как CNN и иные типы нейронных сетей, использующие в качестве классификатора, как правило, функцию softmax на последнем слое [40, 41, 156]. При этом каждый

последующий шаг классификации выстраивается на основании неверно классифицированных объектов на предыдущем шаге посредством увеличения их весовых коэффициентов, таким образом на текущем шаге полученная модель оказывается сфокусированной на ошибочных объектах [41]. На последней итерации работы алгоритма AdaBoost будет сформирована архитектура из наиболее оптимальных по отношению к различным объектам классификаторов. Как правило, метод AdaBoost применяется по отношению к задаче обнаружения и/или детектирования определенных объектов. В частности, на примере обнаружения объектов базы MSTAR настоящий подход позволяет достигать точности распознавания до 99% [40, 41, 269, 270], и показывает хорошую робастность по отношению к классическим методам обучения с учителем, например, методам опорных векторов [39]. Существенным недостатком метода AdaBoost является вероятность формирования излишне громоздкой композиции классификаторов, включающей несколько сотен алгоритмов, что, с одной стороны, будет затруднять анализ полученной архитектуры, с другой стороны, будет требовать огромных объемов памяти и существенных временных затрат. Тем не менее, некоторые приемы позволяют привести к последующему снижению требований к вычислительным ресурсам, среди которых следует упомянуть предварительное применение к входным данным метода главных компонент и Фурье-преобразования для снижения их размерности [39–41], а также использование признаков Хаара [271].

1.6.7. Генетический алгоритм

Генетический алгоритм (Genetic Algorithm, GA) представляет собой форму эволюционных вычислений, использующийся для задач оптимизации и моделирования различных процессов с применением случайного подбора параметров, основанном на математическом моделировании процессов эволюции в живой природе. При использовании GA полагается, что решение может быть представлено в виде некоторых параметров (генов), объединённых в структуры данных (хромосомы). Гены могут быть выражены в виде двоичного кода, так и в виде алфавита, а структуры могут представлять собой строки, деревья либо матрицы. Множество потенциальных решений образует популяцию, которое совершенствуется с помощью генетических операторов, отвечающих за изменчивость,

и целевой функции, моделирующей естественный отбор и служащей для оценки пригодности структуры данных. Как правило, целевая функция формализуется на основе принципа минимальной длины описания (MDL) [272, 273]. На начальной итерации формируется случайный набор хромосом, далее происходит формирование последующих поколений с учетом их приспособленности и изменчивости, на последнем шаге осуществляется выбор наилучших решений [274]. Применительно к задачам классификации изображений ГА могут выступать как в роли инструмента обучения без учителя, так и использоваться для поиска наиболее эффективных признаков обучающей выборки. При интегрировании ГА с алгоритмами обучения без учителя сегментация выступает в роли задачи оптимизации, в ходе которой ГА позволяют эффективно анализировать гиперпространство признаков, находя с помощью целевой функции состояние с наибольшей разделимостью классов [273]. Так, сочетание ГА с ЕМ-алгоритмом позволяет получить на выходном продукте до 95 % адекватно сегментированных пикселей [272], а предварительное использование оператора Кэнни к исходному РЛИ и оптимизация целевой функции под задачу поиска контуров позволяет эффективно обнаруживать границы дорожной сети даже на данных РЛИ высокого разрешения [275].

В случае подхода, основанного на обучении с учителем, генетические алгоритмы выступают в роли инструмента, позволяющего отобрать наиболее удачные признаки элементов обучающей выборки, что позволяет избежать эффекта переобучения и в конечном счете снизить вычислительные затраты [216, 273, 276, 277]. В качестве классификатора при этом могут выступать различные рассмотренные выше методы, например, байесовский классификатор [273], метод разреженных представлений [216], сети радиально-базисных функций (RBF) [277]. Дополнительные приемы, такие как вейвлет преобразование элементов обучающей выборки [277] и предварительная свертка между фрагментами обучающей выборки и моделями ASC, на примере объектов базы MSTAR позволяют достичь точности распознавания до 95 % и выше [216, 276].

Несмотря на то, что генетические алгоритмы позволяют решать неформализованные задачи и в сочетании с другими методами классификации изображений позволяют достичь высокой точности распознавания, сама процедура организации эволюционных вычислений достаточно

трудоемкая, а их применение не гарантирует того, что итоговое решение окажется оптимальным [278]. Также следует отметить, что процедура оптимизации признаков обучающей выборки, предназначенной для сокращения времени процедуры распознавания, может потребовать существенного времени для достижения приемлемой сходимости. Таким образом, применение генетических алгоритмов оказывается оправданным тогда, когда необходимо получить приемлемый результат за сравнительно небольшое время, поэтому в последние годы в задаче распознавания образов на изображениях GA встречаются все реже.

1.6.8. Вывод по разделу 1.6

Использование методов глубокого обучения, основанных на ИНС, в задачах распознавания РЛИ является наиболее мощным инструментом, обеспечивающим точность распознавания на отдельных типах объектов до 99% и выше. Однако следует отметить, что применительно к радиолокационным данным для достижения столь впечатляющих результатов любая архитектура нейронных сетей по-прежнему требует учета специфики данных в виде чувствительности к ракурсу и наличию спекл-шума и не может быть использована без предварительных модификаций. Процесс обучения ИНС является достаточно трудоемким даже с учетом применения различных приемов по отношению к входным данным, таких как уменьшение размерности пространства признаков и использование генетических алгоритмов, поэтому методы глубокого обучения к задачам распознавания образов на РЛИ не могут быть применены в режиме реального времени. Еще одним существенным недостатком использования ИНС является требование к большому объему обучающей выборки (несколько тысяч элементов и более), в противном случае нейронная сеть окажется переобученной, что может привести к точности распознавания даже более низкой, чем традиционными методами обучения с учителем. Таким образом, перед применением любой ИНС необходимо либо заблаговременно подготовить достаточное количество образцов для ее эффективного обучения, либо применять дополнительные приемы, например, расширять выборку за счет использования генеративно-сопоставительных сетей, что опять же требует временных ресурсов. Наконец, при работе с более-менее глубокой (содержавшей существенное количество слоев)

ИНС раскрытие ее топологии представляется невозможным, что известно, как эффект черного ящика. Это означает, что ИНС представляет собой неидентифицируемую модель, что, в свою очередь, затрудняет оценку точности результатов ее работы.

1.7. Вывод к главе 1

Анализ работ, посвященных различным методам классификации и распознавания РЛИ, позволяет сделать следующие выводы:

1. Не существует единых подходов к оценке надежности используемых алгоритмов. Подавляющее большинство работ содержит оценку точности, произведенную по некоторому набору тестовых данных, при этом аналитические исследования возможностей приведенных методов, как правило, отсутствуют, а выбор оптимального метода зачастую осуществляется лишь по принципу сравнения между конкурирующими алгоритмами;

2. В работах, содержащих анализ точности, как правило, анализируются расчетные величины ошибок ложного срабатывания и ошибок пропуска, а также различных зависимостей, полученных на их основе, в то время как современные задачи распознавания образов выходят за пределы бинарного подхода к анализу полученных результатов и требуют более гибкого инструмента для оценки потенциальных возможностей используемых алгоритмов;

3. Обзор литературы показывает, что при выборе конкретного метода классификации необходимо искать компромисс между точностью получаемых результатов и скоростью вычислений, причем замедлению вычислений способствуют как подготовка и анализ исходных данных, так и сама расчетная процедура. Учитывая активное расширение задач, в которых находит свое применение область ДЗЗ, вопрос оперативности получаемых результатов встает особенно остро, и несмотря на то, что глубокие методы обучения позволяют распознавать объекты на РЛИ с точностью, приближающуюся к 100 %, зачастую оператор не располагает временем, необходимым для должной подготовки опорных данных;

4. Существующие работы по распознаванию образов и классификации РЛИ содержат экспериментальный раздел, посвященный использованию алгоритмов применительно к конкретным типам объектов, причем в качестве таких объектов в значительной части

исследований выступают военные транспортные средства базы MSTAR, геометрические, яркостные и структурные параметры которых являются достаточно специфичными. Это позволяет сделать вывод об узкой направленности приведенных в главе алгоритмов, тогда как реальные природные объекты могут обладать существенной изменчивостью даже в пределах одной сцены;

5. За исключением задач, посвященных поиску изменений на разновременных РЛИ, существующие работы посвящены методам, предназначенным для обработки единичного кадра, в то время как в современная тенденция развития космонавтики предполагает активное внедрение группировок малых спутников. Такой подход позволит существенно расширить потенциал в распознавании образов, и современные подходы к обработке РЛИ должны быть адаптированы под меняющуюся ситуацию.

Анализ опубликованных работ позволяет сделать вывод о необходимости разработки принципиально новых подходов с учетом современных тенденций, которые позволяли бы, с одной стороны, осуществлять высокоточное распознавание образов на РЛИ в режиме реального времени, с другой стороны, позволяли бы выполнять гибкую оценку точности без привлечения тестовых данных.

1.8. Литература к главе 1

1. Сойфлер В., Ред., Методы компьютерной обработки изображений, М.: Физматлит, 2003, р. 784.
2. Кондратенков Г., Радиолокационные станции обзора Земли, В. П. и д. Г.С. Кондратенков, Ред., М.: Радио и связь, 1983, р. 272.
3. Kechagias-Stamatis O., «Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey», Computer Vision and Pattern Recognition, т. 36, №3, pp. 56-81, 2021.
4. Xiao Yuan, Tao Tang, Deliang Xiang, Yu Li, Yi Su, «Target recognition in SAR imagery based on local gradient ratio pattern», International Journal of Remote Sensing, т. 35, №3, p. 857–870, 2014.
5. Kuiying Yina, Lin Jina, Changchun Zhanga, Yufeng Guob, «A method for automatic target recognition using shadow contour of SAR image», IETE Technical Review, т. 30, №4, pp. 313-323, 2013.

6. Gholamreza Akbarizadeh, «A New Statistical-Based Kurtosis Wavelet Energy Feature for Texture Recognition of SAR Images», IEEE transactions on geoscience and remote sensing, т. 50, № 11, pp. 4358-4368, 2012.

7. Armando Marino, Maria J. Sanjuan-Ferrer, Irena Hajnsek, Kazuo Ouchi, «Ship Detection with Spectral Analysis of Synthetic Aperture Radar: A Comparison of New and Well-Known Algorithms», Remote sensing, т. 7, pp. 5416-5439, 2015.

8. Min Dai, Cheng Peng, Andrew K. Chan, Dmitri Loguinov, «Bayesian Wavelet Shrinkage With Edge Detection for SAR Image Despeckling», IEEE transactions on geoscience and remote sensing, т. 42, № 8, pp. 1642-1648, 2004.

9. Alin Achim, Panagiotis Tsakalides, Anastasios Bezerianos, «SAR Image Denoising via Bayesian Wavelet Shrinkage Based on Heavy-Tailed Modeling», IEEE transactions on geoscience and remote sensing, т. 41, № 8, pp. 1773-1784, 2003.

10. Pal S.K., Majumdar T.J., Bhattacharya A.K., «Extraction of linear and anomalous features using ERS SAR data over Singhbhum Shear Zone, Jharkhand using fast Fourier», International Journal of Remote Sensing, т. 27, № 20, p. 4513–4528, 2006.

11. Ganggang Dong, Hongwei Liu, Gangyao Kuang, Jocelyn Chanussot, «Target recognition in SAR images via sparse representation in the frequency domain», Pattern Recognition, 2019.

12. Namias V., «The fractional order Fourier transform and its application to quantum mechanics», Journal of Institute of Mathematics and its Applications, № 25, pp. 241-265, 1980.

13. Radon J., «Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten», Berichte Sächsische Akademie der Wissenschaften, № 69, p. 262–277, 1917.

14. Copeland A.C., Ravichandran G., Trivedi M.M., «Localized Radon Transform-Based Detection of Ship Wakes in SAR Images», IEEE Transactions on Geoscience and Remote Sensing, т. 33, № 1, pp. 35-45, 1995.

15. Courmontagne P., «An improvement of ship wake detection based on the radon transform», Signal Processing, т. 85, № 8, pp. 1634-1654, 2005.

16. Yunping Chen, Yang Li, Huixiong Zhang, Ling Tong, Yongxing Cao, Zhihang Xue, «Automatic power line extraction from high resolution remote sensing imagery based on an improved Radon transform», Pattern Recognition, т. 49, pp. 174-186, 2016.

17. Murphy L. M., «Linear feature detection and enhancement in noisy images via the Radon transform», Pattern Recognition, т. 4, №4, pp. 279-284, 1986.
18. G. O. L. L. P. E. Magli, «Pattern recognition by means of the Radon transform and the continuous wavelet transform», Signal Processing, т. 73, pp. 277-289, 1999.
19. H. P.V.C., «Methods, Means for Recognizing Complex Patterns». U.S. Патент 3069654, 1962.
20. Ballard D., «Generalizing the Hough transform to detect arbitrary shapes», Pattern Recognition, т. 13, №2, pp. 111-122, 1981.
21. Skingley J., Rye A.J., «The Hough transform applied to SAR for thin line detection», Pattern Recognition, т. 6, pp. 61-67, 1987.
22. Pi Y., Fan L., Yang X., «Geoscience and Remote Sensing Symposium», в Airport Detection and Runway Recognition in SAR Images, 2003.
23. Cheng-Li J., Ke-Feng J., Yong-Mei J., Gang-Yao K., «International Geoscience and Remote Sensing Symposium», в Road Extraction from High-Resolution SAR Imagery Using Hough, 2005.
24. Mallat S., «A theory for multiresolution signal decomposition: the wavelet representation», Transactions on Pattern Analysis and Machine Intelligence, т. 11, № 7, pp. 674-693, 1989.
25. Dong G., Kuang G., Wang N., Wang W., «Classification via Sparse Representation of Steerable Wavelet Frames on Grassmann Manifold: Application to Target Recognition in SAR Image», IEEE transactions on image processing, т. 20, №20, pp. 1-13, 2017.
26. Tello M., Lopez-Martinez C., Mallorqui J.J., «A Novel Algorithm for Ship Detection in SAR Imagery Based on the Wavelet Transform», IEEE Geoscience and Remote Sensing Letters, т. 2, №2, pp. 201-205, 2005.
27. Ovarlez J.-P., Vignaud L., Castelli J.-C., Tria M., Benidir M., «Analysis of SAR images by multidimensional wavelet transform», Radar, Sonar and Navigation, т. 150, №4, p. 234-241, 2003.
28. Bovolo F., Bruzzone L., «A Detail-Preserving Scale-Driven Approach to Change Detection in Multitemporal SAR Images», IEEE Transactions on Geoscience and Remote Sensing, т. 43, № 12, pp. 2963-2972, 2005.
29. Zhou Z., Wang M., Cao Z., Pi Y., «SAR Image Recognition with Monogenic Scale Selection-Based Weighted Multi-task Joint Sparse Representation», Remote Sensing, т. 10, pp. 504-513, 2018.

30. Dong G., Kuang G., Wang N., Dong G., Kuang G., Wang N., Zhao L., Lu J., «SAR Target Recognition via Joint Sparse Representation of Monogenic Signal», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 8, № 7, pp. 3316-3328, 2015.
31. Chatelain F., Tournet J.-Y., Inglada J., «Change Detection in Multi-sensor SAR Images Using Bivariate Gamma Distributions», *IEEE transactions on image processing*, т. 17, № 3, pp. 249-258, 2008.
32. M Amoon, GA Rezai-Rad, «Automatic target recognition of synthetic aperture radar (SAR) images based on optimal selection of Zernike moments features», *IET Computer Vision*, т. 8, № 2, p. 77–85, 2014.
33. XZ Zhang, Z Liu, S Liu, D Li, Y Jia, «Sparse coding of 2D-slice Zernike moments for SAR ATR», *International journal of remote sensing*, т. 38, № 2, p. 412–431, 2017.
34. Bolourchi P., Moradi M., Demirel H., Uysal S., «20th International Conference on Modelling & Simulation», в *Random Forest Feature Selection for SAR ATM*, 2018.
35. K. P. F.R.S., «On lines and planes of closest fit to systems of points in space», *Philosophical Magazine*, т. 2, p. 559—572, 1901.
36. Qun Zhao, Jose C. Principe, Victor Brennan, Dongxin Xu, Zheng Wang, «Synthetic Aperture Radar Automatic Target Recognition with Three Strategies of Learning and Representation», *Optical Engineering*, т. 39, № 5, 2000.
37. Wu Tao, Chen Xi, Ruang Xiangwei, Niu Lei, «Study on SAR Target Recognition Based on Support Vector Machine», в *2nd Asian-Pacific Conference on Synthetic Aperture Radar*, 2009.
38. P Du, A Samat, B Waske, S Liu, Z Li, «Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features», *ISPRS Journal of Photogrammetry and Remote Sensing*, т. 105, pp. 38-53, 2015.
39. Ying Wang, Ping Han, Xiaoguang Lu, Renbiao Wu, Jingxiong Huang, «The Performance Comparison of Adaboost and SVM Applied to SAR ATR», в *CIE International Conference on Radar*, 2007.
40. Zhang F., Wang Y., Ni J., Zhou Y., «SAR Target Small Sample Recognition Based on CNN Cascaded Features and AdaBoost Rotation Forest», *IEEE geoscience and remote sensing letters*, т. 17, № 6, pp. 1008-1012, 2020.
41. Sun Y., Liu Z., Todorovic S., Li J., «Adaptive Boosting for SAR Automatic Target Recognition», *IEEE Transactions on Aerospace and Electronic Systems*, т. 43, № 1, pp. 112-125, 2007.

-
42. C. P., «Independent Component Analysis: a new concept?», *Signal Processing*, т. 36, №3, p. 287–314, 1994.
43. Huang C.-W., Lee K.-C., «Application of ICA technique to PCA based radar target recognition», *Progress In Electromagnetics Research*, т. 105, p. 157–170, 2010.
44. Maokuan L., Jian G., Hui D., Xin G., «SAR ATR based on Support Vector Machines and Independent Component Analysis SVM», в *CIE International Conference on Radar*, 2007.
45. Hongyun Y., Jian G., Tao G., Jing Z., «SAR ATR based on Multi-Subspaces of Independent Component Analysis», в *1st Asian and Pacific Conference on Synthetic Aperture Radar*, 2008.
46. «Sensor data management system website, MSTAR database», 1995. [B Интернетe]. Available: <https://www.sdms.afrl.af.mil/index.php?collection=mstar>.
47. M. I., «Structured low-rank approximation and its applications», *Automatica*, т. 44, №4, pp. 891-909, 2008.
48. Dang S., Cui Z., Cao Z., Liu N., «SAR Target Recognition via Incremental Nonnegative Matrix Factorization», *Remote Sensing*, т. 10, №3, pp. 374-382, 2018.
49. Cui Z., Feng J., Cao Z., Yang J.M., «Target recognition in synthetic aperture radar images via non-negative matrix factorization», *IET Radar, Sonar & Navigation*, т. 9, №9, 2015.
50. Yu M., Dong G., Fan H., Kuang G., «SAR Target Recognition via Local Sparse Representation of Multi-Manifold Regularized Low-Rank Approximation», *Remote Sensing*, т. 10, №2, pp. 211-219, 2018.
51. Yu M., Zhang S., Zhang L., Zhao L., Kuang G., «SAR Target Recognition via Joint Manifold Regularized Low-Rank Matrix Approximation», в *19th International Radar Symposium (IRS)*, 2018.
52. Zhang X., Wang Y., Li D., Tan Z., Liu S., «Fusion of Multifeature Low-Rank Representation for Synthetic Aperture Radar Target Configuration Recognition», *IEEE Geoscience and Remote Sensing Letters*, т. 15, №9, pp. 1402-1406, 2018.
53. Wang Y., Zheng Q., «Recognition of roads and bridges in SAR images», *Pattern Recognition*, т. 31, №7, pp. 953-962, 1998.
54. Zaart A.I., Ziou D., Wang S., Jiang Q., «Segmentation of SAR images», *Pattern Recognition*, т. 35, p. 713–724, 2002.

55. Kittler J.J., Illingworth J., «Minimum error thresholding», Pattern Recognition, т. 19, № 1, pp. 41-47, 1986.

56. Dellepiane S., Giusto D.D., Serpico S.B., Vernazza G., «SAR image recognition by integration of intensity and textural information», International Journal of Remote Sensing, т. 12, № 9, pp. 1915-1932, 1991.

57. Bazi Y., Bruzzone L., Melgani F., «An unsupervised approach based on the generalized gaussian model to automatic change detection in multitemporal SAR images», IEEE Transactions on Geoscience and Remote Sensing, т. 43, № 4, pp. 874-887, 2007.

58. Akbarizadeh G., Rezai-Rad G.A., Shokouhi B., «A New region-Based active contour model with skewness wavelet energy for segmentation of SAR images», IEICE Transactions on Information and Systems, T. %1 из %293-D, № 7, pp. 690-1699, 2010.

59. Tan H, Yang G, Zheng N, Luo T, «An improvement of two-dimensional maximum entropy thresholding segmentation algorithm for SAR image», в International Conference on Computer Science and Electronics Engineering, Hangzhou, 2012.

60. Nobre R H., Rodrigues F A. A., Marques R C. P., Nobre J S., Neto J F. S. R., Medeiros F N. S., «SAR Image Segmentation With Renyi's Entropy», Signal processing letters, т. 23, № 11, pp. 1551-1555, 2016.

61. A Al-Ajlan, A El-Zaart, «Image segmentation using minimum cross-entropy thresholding», в Proceedings of the 2009 IEEE International Conference on Systems, Man, and Cybernetics, 2009.

62. Kekre H.B., Gharge S., Sarode T.K., «SAR Image Segmentation using Vector Quantization Technique on Entropy Images», International Journal of Computer Science and Information Security, т. 7, № 3, 2010.

63. Liu J Z, Li W Q, Tian Y P, «Automatic threshold of gray-level pictures using two-dimensional Otsu method», в Proceedings of International Conference on Circuits and Systems, Shenzhen, 1991.

64. Guo Y., Zhang J., «A new 2D Otsu for water extraction from SAR image», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, T. %1 из %2XLII-2/W7, pp. 733-736, 2017.

65. Yu F, Sun W, Li J, Zhao Y, Zhang Y, Chen G, «An improved Otsu method for oil spill detection from SAR images», Oceanologia, т. 59, № 3, pp. 311-317, 2017.

66. Chen Q. Zhao L. Lu J. Kuang G. Wang N. Jiang Y., «Modified two-dimensional Otsu image segmentation algorithm and fast realisation», *ET Image Processing*, т. 6, №4, p. 426–433, 2012.
67. L. S., «Least squares quantization in PCM», in *IEEE Transactions on Information Theory*, т. 28, №2, pp. 129-137, 1982.
68. Samanta D, Paul M, Sanyal G, «Segmentation Technique of SAR Imagery using Entropy», *International Journal of Computer Applications in Technology*, т. 2, №5, pp. 1548-1551, 2011.
69. Liu L.,ia Zh., Yang J., Kasabov N.K., «SAR Image Change Detection Based on Mathematical Morphology and the K-Means Clustering Algorithm», *IEEE Access*, т. 7, pp. 43970-43978, 2019.
70. Niharika E., Adeeba H, Sh A. Krishna R, Yugander P., «K-means based Noisy SAR Image Segmentation using Median Filtering and Otsu Method», в *2017 International Conference on IoT and Application*, Nagapattinam, 2017.
71. Bezdek J. C., «Pattern Recognition with Fuzzy Objective Function Algorithms», 1981.
72. Wan L., Zhang T., Xiang Y., You H., «A Robust Fuzzy C-Means Algorithm Based on Bayesian Nonlocal Spatial Information for SAR Image Segmentation», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, №3, pp. 896-906, 2018.
73. Shang R., Chen Ch., Wang G., Jiao L., Okoth M.A., Stolkin R., «A thumbnail-based hierarchical fuzzy clustering algorithm for SAR image segmentation», *Signal Processing*, т. 171, pp. 1-9, 2020.
74. Gui Y., Zhang X., Shang Y., «SAR image segmentation using MSER and improved spectral clustering», *EURASIP Journal on Advances in Signal Processing*, т. 83, pp. 1-9, 2012.
75. Rahmani M., Akbarizadeh Gh., «Unsupervised feature learning based on sparse coding and spectral clustering for segmentation of synthetic aperture radar images», *IET Computer Vision*, т. 9, №5, p. 629–638, 2015.
76. Liua, F. Zhao, L. Jiao H., «Fuzzy spectral clustering with robust spatial information for image segmentation», *Applied Soft Computing*, т. 12, №11, pp. 3636-3647, 2012.
77. Shang R., Tian P., Jiao L., Stolkin R., Feng J., Hou B., Zhang X., «A Spatial Fuzzy Clustering Algorithm With Kernel Metric Based on Immune Clone for SAR Image Segmentation», *IEEE Journal of selected topics in applied earth observations and remote sensing*, т. 9, №4, pp. 1640-1652, 2016.

78. Zhang X, Jiao L, Liu F, Bo L, Gong M, «Spectral Clustering Ensemble Applied to SAR Image Segmentation», IEEE Transactions on geoscience and remote sensing, т. 46, № 7, pp. 2126-2136, 2008.

79. Gou Sh., Zhuang X., Zhu, H. Yu T., «Parallel Sparse Spectral Clustering for SAR Image Segmentation», IEEE Journal of selected topics in applied earth observations and remote sensing, т. 6, №4, pp. 1949-1963, 2013.

80. Baghi A., Karami A., «SAR image segmentation using region growing and spectral cluster», в 3rd International Conference on Pattern Recognition and Image Analysis, 2017.

81. Yu P., Qin A.K., Clausi D.A., «Clausi Unsupervised Polarimetric SAR Image Segmentation and Classification Using Region Growing With Edge Penalty», IEEE Transactions on geoscience and remote sensing, т. 50, №4, pp. 1302-1317, 2012.

82. Sharma R., Sharma R., «Image Segmentation using Morphological Operations for Automatic Region Growing», International Journal of Computer Science and Information Technologies, т. 4, №6, pp. 844-847, 2013.

83. Lira J., Frulla L., «An automated region growing algorithm for segmentation of texture regions in SAR images», International Journal of Remote Sensing, т. 19, № 18, pp. 3595-3606, 1998.

84. Li L., Zhang X., Pu L., Pu L., Tian B., L. Zhou, Sh. Wei, «3D SAR Image Background Separation Based on Seeded Region Growing», IEEE Access, т. 7, pp. 179842-179863, 2019.

85. Yeom J., Jung M., Kim Y., «Detecting damaged building parts in earthquake damaged areas using differential seeded region growing», International Journal of Remote Sensing, т. 38, №4, p. 985–1005, 2017.

86. Nock R., Nielsen F., «Statistical Region Merging», IEEE Transactions on Pattern Analysis and Machine Intelligence, т. 26, № 11, p. 1452–1458, 2004.

87. Lang F, Yang J, Li D, Zhao L, Shi L, «Polarimetric SAR Image Segmentation Using Statistical Region Merging», IEEE Geoscience and remote sensing letters, т. 11, №2, pp. 509-513, 2014.

88. Zhang H, Ni W, Yan W, Bian H, Wu J, Li Sh, «SAR Image Change Detection using Modified Statistical Region Merging», в 4th International Conference on Computer Science and Network Technology, Harbin, 2015.

89. Hu Y., Fan J., Wang J., «Target Recognition of Floating Raft Aquaculture», в Seventh International Conference on Information Science and Technology, 2017.

90. R.G. W., «Change detection in SAR imagery», *International Journal of Remote Sensing*, т. 12, №2, pp. 339-360, 1991.
91. Li W., Benie G.B., He D.-Ch., Wang Sh., Ziou D., Hugh Q., J. Gwyn, «Watershed-based hierarchical SAR image segmentation», *International Journal of Remote Sensing*, т. 20, №17, pp. 3377-3390, 1999.
92. Fjørtoft R., Lopes A., Marthon P., Cubero-Castan E., «An Optimal Multiedge Detector for SAR Image Segmentation», *IEEE Transactions on geoscience and remote sensing*, т. 36, №3, pp. 793-802, 1998.
93. Kass M., Witkin A., Terzopoulos D., «Snakes: Active Contour Models», *International Journal of Computer Vision*, pp. 321-331, 1998.
94. Zhang X. Xiong B., Dong G., Kuang G., «Ship Segmentation in SAR Images by Improved Nonlocal Active Contour Model», *Sensors*, т. 18, №12, pp. 4220-434, 2018.
95. Tu, S.; Su, Y.; Li, Y., «Convex active contour model for target detection in synthetic aperture radar images», *Journal of Applied Remote Sensing*, т. 9, pp. 1-24, 2015.
96. Shuai, Y., Sun, H., Xu, G., «SAR image segmentation based on level set with stationary global minimum», *IEEE Geoscience and remote sensing letters*, т. 5, p. 644–648, 2008.
97. Liu J., Wen X., Meng Q., Xu H., Yuan L., «Synthetic Aperture Radar Image Segmentation with Reaction Diffusion Level Set Evolution Equation in an Active Contour Model», *Remote sensing*, т. 10, pp. 1-16, 2018.
98. Ayed I.B., Vdiquez C., Mitiche A., Belhacj Z., «SAR image segmentation with active contours and level sets», в *2004 International Conference on Image Processing*, 2004.
99. Ayed, I.B., Hennane, N., Mitiche, A., «Unsupervised variational image segmentation/classification using a Weibull observation model», *IEEE Transactions on Image Processing*, т. 15, p. 3431–3439, 2006.
100. Song H., Huang B., Zhang K., «A Globally Statistical Active Contour Model for Segmentation of Oil Slick in SAR Imagery», *IEEE Journal of selected topics in applied earth observations and remote sensing*, т. 6, №6, pp. 2402-2409, 2013.
101. Xia G.-S., Liu G., Yang W., Zhang L., «Meaningful Object Segmentation From SAR Images via a Multiscale Nonlocal Active Contour Model», *IEEE Transactions on geoscience and remote sensing*, т. 54, №3, pp. 1860-1873, 2016.

102. Germain O., Ph. Réfrégier, «Edge Location in SAR Images: Performance of the Likelihood Ratio Filter and Accuracy Improvement with an Active Contour Approach», IEEE Transactions on image processing, т. 10, № 1, pp. 72-78, 2001.

103. M.S. H., «A statistical active contour model for SAR image segmentation», Image and Vision Computing, т. 17, № 3-4, pp. 213-224, 1999.

104. Han B., Wu Y., «A novel active contour model driven by J-divergence entropy for SAR river image segmentation», Pattern Analysis and Applications, т. 21, p. 613-627, 2018.

105. Javed U., Riaz M.M., Ghafoor A., Cheema T.A., «SAR Image Segmentation Based on Active Contours With Fuzzy Logic», IEEE Transactions on aerospace and electronic systems, т. 52, № 1, pp. 181-188, 2016.

106. Wu Y., Ma W., Gong M., Li H., Jiao L., «Novel fuzzy active contour model with kernel metric for image segmentation», Applied Soft Computing, т. 34, pp. 301-311, 2015.

107. Han B., Wu Y., Basu A., «Adaptive Active Contour Model Based on Weighted RBPF for SAR Image Segmentation», IEEE Access, т. 7, pp. 54522-54532, 2019.

108. Meng Q., Wen X., Yuan L., Xu H., «Factorization-Based Active Contour for Water-Land SAR Image Segmentation via the Fusion of Features», IEEE Access, т. 7, pp. 40347-40358, 2019.

109. Smits P.C., Dellepiane S.G., «Synthetic aperture radar image segmentation by a detail preserving Markov random field approach», IEEE Transactions on Geoscience and Remote Sensing, т. 35, № 4, pp. 844-857, 1997.

110. S.Z. L., Markov random field modeling in computer vision, Tokyo: Springer-Verlag, 1995.

111. O Lankoande, MM Hayat, B. Santhanam, «Segmentation of SAR Images Based on Markov Random Field Model», в IEEE International Conference on Systems, Man and Cybernetics, Waikoloa, USA, 2005.

112. Lei X., Li Y., Zhao N., Zhang Y., «Fast segmentation approach for SAR image based on simple Markov random field», Journal of Systems Engineering and Electronics, т. 21, № 1, p. 31-36, 2010.

113. Zhanga P., Lia M., Wub Y., Ana L., Jia L., «Unsupervised SAR Image Segmentation Using High-Order Conditional Random Fields Model based on Product-of-Experts», Pattern Recognition Letters, т. 78, № 15, pp. 48-55, 2016.

114. Zhang P., Li M., Wu Y., Li H., «Hierarchical Conditional Random Fields Model for Semisupervised SAR Image Segmentation», IEEE transactions on geoscience and remote sensing, т. 53, №9, pp. 4933-4951, 2015.
115. Li M., Wub Y., Zhang Q., «SAR image segmentation based on mixture context and wavelet hidden-class-label Markov random field», Computers and Mathematics with Applications, т. 57, №6, pp. 961-969, 2009.
116. Xia G.-S., He C., Sun H., «Integration of synthetic aperture radar image segmentation method using Markov random field on region adjacency graph», IET Radar Sonar Navigation, т. 1, №5, pp. 348-353, 2007.
117. Yu Q., Clausi D.A., «IRGS: Image Segmentation Using Edge Penalties and Region Growing», IEEE Transactions on pattern analysis and machine intelligence, т. 30, №12, pp. 2126-2139, 2008.
118. Clausi D.A., Yue B., «Comparing Cooccurrence Probabilities and Markov Random Fields for Texture Analysis of SAR Sea Ice Imagery», IEEE transactions on geoscience and remote sensing, т. 42, №1, pp. 214-228, 2004.
119. Zhang R., Zhang M., «SAR target recognition based on active contour without edges», Journal of Systems Engineering and Electronics, т. 28, №2, p. 276–281, 2017.
120. Li H. T., Gu H.Y., Han Y. S., Yang J. H., «Object-oriented Classification of Polarimetric SAR Imagery based on Statistical Region Merging and Support Vector Machine», в International Workshop on Earth Observation and Remote Sensing Applications, Beijing, 2008.
121. Lang F., Yang J., Zhao L., Li D., «Hierarchical classification of polarimetric SAR image based on statistical region merging», ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, т. 1, №7, pp. 147-152, 2012.
122. Дуда П. Х. Р., Распознавание образов и анализ сцен, В. Стефанюк, Ред., М.: Мир, 1976, p. 507.
123. Скрыпник О.Н., Лежанкин Б.В., Малов А.Н., Миронов Б.М., Галиев С.Ф., «Формирование классификационной карты подстилающей поверхности по изображениям от когерентного локатора», Компьютерная оптика, т. 29, pp. 151-159, 2006.
124. Chen Ch., Huang K., Gao G., «Small-Target Detection between SAR Images Based on Statistical Modeling of Log-Ratio Operator», Sensors, т. 19, №6, pp. 1431-1440, 2019.

125. Oh J., Youm G.Y., Kim M., «SPAM-Net: A CNN-Based SAR Target Recognition Network With Pose Angle Marginalization Learning», IEEE transactions on circuits and systems for video technology, т. 31, №2, pp. 701-714, 2021.

126. Huang P., Qiu W., «A robust decision fusion strategy for SAR target recognition», Remote Sensing Letters, т. 9, №6, p. 507–514, 2018.

127. Chiang H.-C., Moses R.L., Potter L.C., «Model-based Bayesian feature matching with application to synthetic aperture radar target recognition», Pattern Recognition, т. 34, №8, pp. 1539-1553, 2001.

128. Liu J., Chang K.-C., «Feature-Based Target Recognition with Bayesian Inference», в Uncertainty Modeling and Analysis, International Symposium, 1995.

129. Kullback S., Leibler R.A., «On information and sufficiency», The Annals of Mathematical Statistics, т. 22, №1, pp. 79-86, 1951.

130. Song Sh., Xu B., Li Z., Yang J., «Ship Detection in SAR Imagery via Variational Bayesian Inference», IEEE Geoscience and Remote Sensing Letters, т. 13, №3, pp. 319-323, 2016.

131. К. С. А. Л. С. А. Коренной А.В., «Способ распознавания и определения параметров образа объекта на радиолокационном изображении». Российская Федерация Патент RU 2516000 C2, 20 май 2014.

132. Huang Q. W. P., «A robust decision fusion strategy for SAR target recognition», Remote Sensing Letters, т. 9, №6, p. 507–514, 2018.

133. Liu J., Chang K.-C., «Automatic Target Recognition with Bayesian Networks», в IFAC Proceedings Volumes, 1996.

134. Ruohong Huan, Yun Pan, Keji Mao, «SAR Image Target Recognition Based on NMF Feature Extraction and Bayesian Decision Fusion», в Second IITA International Conference on Geoscience and Remote Sensing, 2010.

135. Ma W., Wu Y., Gong M., Xiong Y., «Change detection in SAR images based on matrix factorisation and a Bayes classifier», International Journal of Remote Sensing, т. 40, №4, pp. 1-26, 2018.

136. Jia M., Wang L., «Novel class-relativity non-local means with principal component analysis for multitemporal SAR image change detection», International Journal of Remote Sensing, т. 39, №4, pp. 1068-1091, 2018.

137. Liping Hu and Xiaoyu Xing, «SAR target feature extraction and recognition based multilinear principal component ana», в Proc. SPIE 9301, International Symposium on Optoelectronic Technology and Application 2014: Image Processing and Pattern Recognition, 2014.

138. Lin Ch., Peng F., Wang B.-H., Sun W.-F., Kong X.-J., «Research on PCA and KPCA Self-Fusion Based MSTAR SAR Automatic Target Recognition Algorithm», *Journal of electronic science and technology*, т. 10, №4, pp. 352-357, 2012.
139. Monga V., Raj R.G., «SAR Automatic Target Recognition Using Discriminative Graphical Models», *IEEE transactions on aerospace and electronic systems*, т. 50, № 1, pp. 591-606, 2014.
140. Liu H., Li Sh., «Decision fusion of sparse representation and support vector machine for SAR image target recognition», *Neurocomputing*, т. 113, p. 97–104, 2013.
141. Dai K, Lyu W, Luo S, Shi Q, «Bayesian sparse representation model for SAR image classification», *Journal of Applied Remote Sensing*, т. 13, №4, 2019.
142. Li C., Guohua Liu G., «Block Sparse Bayesian Learning over Local Dictionary for Robust SAR Target Recognition», *International Journal of Optics*, 2020.
143. Ren H., Yu X., Bruzzone L., Zhang Y., Zou L., Wang X., «A Bayesian Approach to Active Self-Paced Deep Learning for SAR Automatic Target Recognition», *IEEE geoscience and remote sensing letters*, 2020.
144. Chen S., Wang H., «SAR Target Recognition Based on Deep Learning», в *International Conference on Data Science and Advanced Analytics (DSAA)*, Shanghai, 2014.
145. Bolourchi P., Moradi M., Demirel H., Uysal S., «Improved SAR target recognition by selecting moment methods based on Fisher score», *Signal, Image and Video Processing*, т. 14, pp. 39-47, 2020.
146. Han P., Wu R., Wang Y., Wang Zh., «An efficient SAR ATR approach», в *IEEE International Conference on Acoustics, Speech, and Signal Processing*, Hong Kong, 2003.
147. Huan R., Liang R. and Pan Y., «SAR Target Recognition with the Fusion of LDA and ICA», в *International Conference on Information Engineering and Computer Science*, Wuhan, 2009.
148. He J., Wang Y., Liu H., «Ship Classification in Medium-Resolution SAR Images via Densely Connected Triplet CNNs Integrating Fisher Discrimination Regularized Metric Learning», *IEEE Transactions on Geoscience and Remote Sensing*, т. 59, №4, pp. 3022-3039, 2021.
149. Liu G., Li L., Jiao L., «Stacked Fisher Autoencoder for SAR Change Detection», *Pattern Recognition*, т. 96, №2, 2019.
150. Cramer J.S., «The origins of logistic regression (Technical report)», *Tinbergen Institute*, т. 119, p. 167–178, 2002.

151. Borghys D., Yvinec Y., Perneel C., «Supervised Feature-Based Classification of Multi-Channel SAR Images», *Pattern Recognition Letters* 27(4), т. 27, №4, pp. 252-258, 2005.

152. Albergaa V., Borghysa D., Satalinob G., Staykovac D.K., Borghgrae-fa A., Lapierre F., Perneel C., «Comparison of algorithms for the classification of polarimetric SAR data», в *Proceedings of SPIE – The International Society for Optical Engineering*, 2009.

153. Wang J., Liu J., Ren P., Qin Ch.-X., «A SAR Target Recognition Based on Guided Reconstruction and Weighted Norm-Constrained Deep Belief Network», *IEEE Access*, т. 8, pp. 181712-181722, 2020.

154. Ge S., Lu J., Gu H., Yuan Z., Su W., «Polarimetric SAR Image Classification Based on Deep Belief Network and Superpixel Segmentation», в *3rd International Conference on Frontiers of Signal Processing (ICFSP)*, Paris, 2017.

155. Lv Q., Dou Y., Niu X., Xu J., Li B., «Classification of land cover based on deep belief networks using polarimetric RADARSAT-2 data», в *IEEE Geoscience and Remote Sensing Symposium*, Quebec, 2014.

156. Qin, F., Guo, J., and Sun, W., «Object-oriented ensemble classification for polarimetric sar imagery using restricted boltzmann machines», *Remote Sensing Letters*, т. 8, №3, p. 204–213.

157. Ding J., Chen B., Liu H., Huang M., «Convolutional Neural Network With Data Augmentation for SAR Target Recognition», *IEEE geoscience and remote sensing letters*, т. 13, №3, pp. 364-368, 2016.

158. Minkler M. J. G., *CFAR: The principles of automatic radar detection in clutter*, Baltimore: Magellan Book Co., 1990, p. 384.

159. Touzi R., Lopes A., Bousquet P., «A Statistical and Geometrical Edge Detector for SAR Images», *IEEE transactions on geoscience and remote sensing*, т. 26, №6, pp. 764-773, 1988.

160. Cui Z., Quan H., Cao Z., Xu S., Ding C., «SAR target CFAR detection via GPU parallel operation», *IEEE journal of selected topics in applied earth observations and remote sensing*, т. 11, №12, pp. 4884-4894, 2018.

161. Chandgude C.P., Chawan P.W., «Ship Detection from SAR Imagery Using CUDA and Performance Analysis of the System», *Journal of Engineering Research and Applications*, т. 4, №7, pp. 223-228, 2014.

162. Dai H., Du L., Wang Y., Wang Z., «Modified CFAR Algorithm Based on Object Proposals for Ship Target Detection in SAR Images», IEEE geoscience and remote sensing letters, т. 13, № 12, pp. 1925-1929, 2016.
163. Yu W., Wang Y., Liu H., He J., «Superpixel-based CFAR target detection for high-resolution SAR images», IEEE geoscience and remote sensing letters, т. 13, № 5, pp. 730-734, 2016.
164. Qin X., Zhou S., Zou H., Gao G., «A CFAR Detection Algorithm for Generalized Gamma Distributed Background in High-Resolution SAR Images», IEEE geoscience and remote sensing letters, т. 10, № 4, pp. 806-810, 2013.
165. Gao G., Liu L., Zhao L., Shi G., Kuang G., «An adaptive and fast CFAR algorithm based on automatic censoring for target detection in high-resolution SAR images», IEEE transactions on geoscience and remote sensing, т. 47, № 6, pp. 1685-1697, 2009.
166. E.W. S., «A generalization of the gamma distribution», Annals of Mathematical Statistics, т. 33, № 3, p. 1187–1192, 1962.
167. L.M. K., «Improved SAR target detection via extended fractal features», IEEE transactions on aerospace and electronic systems, т. 37, № 2, pp. 436-451, 2001.
168. Meng W.J., Ju T., Yu Y.H., «CFAR and KPCA for SAR Image Target Detection», в 3rd International Congress on Image and Signal Processing, 2010.
169. «Evaluation of CFAR and Texture Based Target Detection Statistics on SAR Imagery», в Acoustics, Speech, and Signal Processing, 1988 International Conference, 1988.
170. H. E.H., «Long-term storage capacity of reservoirs», Transactions of American Society of Civil Engineers, т. 116, pp. 770-782, 1951.
171. Wang Y., Yu and Q. Yu W., «An improved Normalized Cross Correlation algorithm for SAR image registration», в IEEE International Geoscience and Remote Sensing Symposium, 2012.
172. Li Zh., Bethel J., «Image coregistration in SAR interferometry», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, т. XXXVII, pp. 433-438, 2008.
173. Yague-Martinez N., Eineder M., Brcic R., Breit H., Fritz Th., «TanDEM-X Mission: SAR Image Coregistration Aspects», в EUSAR, 2010.
174. Sansosti Eu, «Geometrical SAR Image Registration», Ieee Transactions On Geoscience And Remote Sensing, т. 44, № 10, pp. 2861-2870, 2006.

175. Yingbing Liu, Yingcheng Zhou, Yongsheng Zhou, Lixiang Ma , Bingnan Wang, and Fan Zhang, «Accelerating SAR Image Registration Using Swarm-Intelligent GPU Parallelization», Ieee Journal of Selected Topics In Applied Earth Observations and Remote Sensing, т. 13, pp. 5694-5703, 2020.

176. Прэт У., Цифровая обработка изображений, т. 1, Москва: Мир, 1982, p. 495.

177. Masato Iehara, Kazuo Ouchi, Isao Takami, Koichi Morimura, and Shintaro Kumano, «Detection of Ships Using Cross-Correlation of Split-Look SAR Images», в Geoscience and Remote Sensing Symposium, 2001.

178. Магдеев Р.Г., Ташлинский А.Г., «Анализ эффективности некоторых методов идентификации объектов на бинарных изображениях», в Всероссийская научно-техническая конференция «Современные проблемы радиоэлектроники», Красноярск, 2014.

179. Ch. G., «Demystifying the Capability of Sublook Correlation Techniques for Vessel Detection in SAR Imagery», IEEE Transactions on Geoscience and Remote Sensing, т. 99, pp. 1-12, 2018.

180. Шовенгердт Р., Дистанционное зондирование. Модели и методы обработки изображений, М.: Техносфера, 2010, p. 556.

181. Maesschalck R. De, Jouan-Rimbaud D., and Massart D.L., «The Mahalanobis distance», Chemometrics and Intelligent Laboratory Systems, т. 50, № 1, p. 1–18, 2000.

182. Wang R., Chen J.-W., Wang Y., Jiao L., «SAR Image Change Detection via Spatial Metric Learning With an Improved Mahalanobis Distance», Geoscience and Remote Sensing Letters, pp. 1-5, 2019.

183. Fiscella B., Giancaspro A., Nirchio F., Pavese P. & Trivero P., «Oil spill detection using marine SAR images», International Journal of Remote Sensing, т. 21, № 18, p. 3561–3566, 2000.

184. Maillard Ph., Clausi D., «Operational Map-Guided Classification of SAR Sea Ice Imagery», IEEE Transactions on Geoscience and Remote Sensing, т. 43, № 12, pp. 2940-2951, 2006.

185. Evelyn F., Hodges J.L., «Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties», Mathematics, 1989.

186. Song S, Xu B, Yang J, «SAR Target Recognition via Supervised Discriminative Dictionary Learning and Sparse Representation of the SAR-HOG Feature», Remote Sensing, т. 8, 2016.

187. Yu X, Li Y, Jiao LC, «SAR Automatic Target Recognition Based on Classifiers Fusion», в International Workshop on Multi-Platform/Multi-Sensor Remote Sensing and Mapping, Xiamen, 2001.
188. Cortes C., Vapnik V., «Support-Vector Networks», Machine Learning, т. 20, pp. 273-297, 1995.
189. Zhao Q., Principe J.C., «Support Vector Machines For Synthetic Aperture Radar Automatic Target Recognition», 2000.
190. Yan F., Mei W., Chunqin Zh., «SAR Image Target Recognition Based on Hu Invariant Moments and SVM», в Proceedings of the Fifth International Conference on Information Assurance and Security, Xi'an, 2009.
191. Aizerman M., Braverman E., and Rozonoer L., «Theoretical foundations of the potential function method in pattern recognition», Automation and Remote Control, т. 25, pp. 821-837, 1964.
192. Wenzel, Florian; Galy-Fajou, Theo; Deutsch, Matthäus; Kloft, Marius, «Bayesian Nonlinear Support Vector Machines for Big Data», Lecture Notes in Computer Science, p. 307–322, 2017.
193. Mountrakis G., Im J., Ogole C., «Support vector machines in remote sensing», Journal of Photogrammetry and Remote Sensing, т. 66, pp. 247-259, 2010.
194. Louis P. Nicoli, Georgios C. Anagnostopoulos, «Shape-based Recognition of Targets in Synthetic Aperture Radar Images using Elliptical Fourier Descriptors», в Automatic Target Recognition XVIII, 2008.
195. Pablo Ruiz, Javier Mateos, Gustau Camps-Valls, Rafael Molina, «Bayesian Active Remote Sensing Image Classification», IEEE Transactions on Geoscience and Remote Sensing, т. 52, №4, pp. 2186-2196, 2014.
196. Thiagarajan J.J., Ramamurthy K.N., Knee P., Spanias A., «Sparse Representations for Automatic Target Classification in SAR Images», в Communications, Control and Signal Processing (ISCCSP), 2010.
197. Bingham E., Mannila H., «Random projection in dimensionality reduction: Applications to image and text data», в Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining, 2001.
198. Mallat S., Zhang Z., «Matching pursuits with time-frequency dictionaries», IEEE Transactions on Signal Processing, т. 41, №22, pp. 3397-3415, 1994.
199. Liu H., Li Sh., «Decision fusion of sparse representation and support vector machine for SAR image target», Neurocomputing, т. 113, pp. 97-104, 2013.

200. Wei Y., Jiao L., Liu F., Yang S., Wu Q., and Sanga G., «Fast DDL Classification for SAR Images with L_{∞} Constraint», IEEE Access, т. 7, p. 68991–69006, 2019.

201. Dong G, Kuang G, «Target Recognition in SAR Images via Classification on Riemannian Manifolds», IEEE Geoscience and remote sensing letters, т. 12, № 1, pp. 199-203, 2015.

202. Zhang Z., «Joint classification of multiresolution representations with discrimination analysis for SAR ATR», Journal of Electronic Imaging, т. 27, № 4.

203. Ding B. and Wen G., «Target recognition of SAR images based on multi-resolution representation», Remote Sensing Letters, т. 8, № 11, p. 1006–1014, 2017.

204. Quinlan J.R., «Induction of Decision Trees», Machine Learning, т. 1, pp. 91-106, 1986.

205. Breiman L., «Random Forests», Machine Learning, т. 45, № 1, pp. 5-32, 2001.

206. Waske B., Braun M.H., «Classifier ensembles for land cover mapping using multitemporal SAR imagery», Journal of Photogrammetry and Remote Sensing, т. 64, № 5, pp. 450-457, 2009.

207. Tongyuan Z., Yang W., Dai D., Sun H., «Polarimetric SAR Image Classification Using Multifeatures Combination and Extremely Randomized Clustering Forests», EURASIP journal on advances in signal processing, т. 2, 2010.

208. Loosvelt L., Peters J., Skriver H., Hans L., «Random Forests as a tool for estimating uncertainty at pixel-level in SAR image classification», International Journal of Applied Earth Observation and Geoinformation, т. 19, № 1, p. 173–184, 2012.

209. Zhu Zh., Woodcock C.E., Rogan J., Kellndorfer J., «Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data», Remote Sensing of Environment, т. 117, pp. 72-82, 2011.

210. A Samat, P Du, MHA Baig, Ch Sumit, Ch Liang, «Ensemble Learning with Multiple Classifiers and Polarimetric Features for Polarized SAR Image Classification», Photogrammetric Engineering & Remote Sensing, т. 13, № 3, pp. 239-251, 2014.

211. Topouzelis K., Psyllos A., «Oil spill feature selection and classification using decision tree forest on SAR image data», ISPRS Journal of Photogrammetry and Remote Sensing, т. 68, pp. 135-143, 2012.

212. Samat A, Du P, MHA Baig, Ch Sumit, Ch Liang , «Ensemble Learning with Multiple Classifiers and Polarimetric Features for Polarized SAR Image Classification», Photogrammetric Engineering & Remote Sensing, т. 13, №3, pp. 239-251, 2014.
213. Xinzhen Zhang, Jianhong Qin, and Guojun Li, «SAR target classification using Bayesian compressive sensing with scattering centers features», Progress In Electromagnetics Research, т. 136, p. 385–407, 2013.
214. Potter L.C. and Moses R.L., «Attributed scattering centers for SAR ATR», IEEE Trans Image Process, т. 6, № 1, pp. 79-91, 1997.
215. Zhang X., «Noise-robust target recognition of SAR images based on attribute scattering center matching», Remote Sensing Letters, т. 10, № 2, pp. 186-194, 2019.
216. Li and T. Du L., «SAR Automatic Target Recognition Based on Attribute Scattering Center Model and Discriminative Dictionary Learning», IEEE Sensors Journal, т. 19, № 12, p. 4598–4611, 2019.
217. Ding B., Wen G., Huang X., Ma C., and Yang X., «Data Augmentation by Multilevel Reconstruction Using Attributed Scattering Center for SAR Target Recognition», IEEE Geoscience and Remote Sensing Letters, т. 14, №6, p. 979–983, 2017.
218. Kuhn H.W., «The Hungarian Method for the assignment problem», Naval Research Logistics Quarterly, т. 2, pp. 83-97, 1955.
219. Ding B., Wen G., Huang X., Ma C., Yang X., «Target Recognition in Synthetic Aperture Radar Images via Matching of Attributed Scattering Centers», IEEE Journal of selected topics in applied Earth observations and remote sensing, т. 10, № 7, pp. 3334-3347, 2017.
220. LeCun Y., Boser B., Denker J.S., Henderson D., Howard R.E., Hubbard W. and Jackel L.D., «Backpropagation Applied to Handwritten Zip Code Recognition», Neural Computation, т. 1, №4, pp. 541-551, 1989.
221. Tian Z., Wang L., Zhan R., Hu J., and Zhang J., «Classification via weighted kernel CNN: application to SAR target recognition», International Journal of Remote Sensing, т. 39, №23, p. 9249–9268, 2018.
222. Г. А.И., Синтез многослойных систем распознавания образов, М.: Энергия, 1974.
223. Bruzzone L., Marconcini M., Wegmuller U., Wiesmann A., «An Advanced System for the Automatic Classification of Multitemporal SAR

Images», *IEEE Transactions on Geoscience and Remote Sensing*, т. 42, №6, pp. 1321-1334, 2004.

224. Gao F., Huang T., Sun J., Wang J., Hussain A., and Yang E., «A New Algorithm for SAR Image Target Recognition Based on an Improved Deep Convolutional Neural Network», *Cognitive computing*, т. 11, №6, p. 809–824, 2019.

225. Wang H., Chen S., Xu F., and Jin Y.-Q., «Application of deep-learning algorithms to MSTAR data», в *IEEE International Geoscience and Remote Sensing Symposium*, 2015.

226. Kwak Y., Song W.-J., and Kim S.-E., «peckle-Noise-Invariant Convolutional Neural Network for SAR Target Recognition», *IEEE Geoscience and Remote Sensing Letters*, pp. 1-5, 2018.

227. Min R., Lan H., Cao Z., and Cui Z., «A Gradually Distilled CNN for SAR Target Recognition», *IEEE Access*, т. 7, p. 42190–42200, 2019.

228. Wang J., Zheng T., Lei P., and Bai X., «Ground Target Classification in Noisy SAR Images Using Convolutional Neural Networks», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, №11, p. 4180–4192, 2018.

229. Shang R., Wang J., Jiao L., Stolkin R., Hou B., and Li Y., «SAR Targets Classification Based on Deep Memory Convolution Neural Networks and Transfer Parameters», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, №8, p. 2834–2846, 2018.

230. He Zh., Lu J., Kuang G., «A Fast SAR Target Recognition Approach Using PCA Features», в *Fourth International Conference on Image and Graphics*, 2007.

231. Yue Zh., Fei G., Xiong Q., Wang J., «A Novel Semi-Supervised Convolutional Neural Network Method for Synthetic Aperture Radar Image Recognition», *Cognitive Computation*, т. 13, №10, 2021.

232. Amrani M. and Jiang F., «Deep feature extraction and combination for synthetic aperture radar target classification», *Journal of Applied Remote Sensing*, т. 11, №4, 2017.

233. Duan Y., Liu F., Jiao L., Zhao P., «SAR Image Segmentation Based on Convolutional-wavelet Neural Network and Markov Random Field», *Pattern Recognition*, т. 64, 2016.

234. Kechagias-Stamatis O., Aouf N., and Belloni C., «SAR Automatic Target Recognition based on Convolutional Neural Networks», в *International Conference on Radar Systems*, 2017.

235. Gao Fei, Huang Teng, Jun Wang, Jinping Sun, «Combining Deep Convolutional Neural Network and SVM to SAR Image Target Recognition», в IEEE Cyber, Physical and Social Computing, 2017.
236. Wagner S.A., «SAR ATR by a combination of convolutional neural network and support vector machines», IEEE Transactions on Aerospace and Electronic Systems, т. 52, №6, p. 2861–2872, 2016.
237. Lv J., Liu Y., «Data Augmentation Based on Attributed Scattering Centers to Train Robust CNN for SAR ATR», IEEE Access, т. 7, 2019.
238. Zhang F., Liu Y., Zhou Y., Yin Q., and Li H.C., «A lossless light-weight CNN design for SAR target recognition», Remote Sensing Letters, т. 11, №5, p. 485–494, 2020.
239. Zhong C., Mu X., He X., Wang J., and Zhu M., «SAR Target Image Classification Based on Transfer Learning and Model Compression», IEEE Geoscience and Remote Sensing Letters, 2018.
240. Heng-Chao Lia, Gang Yanga, Wen Yangb, Qian Duc, William J. Emery, «ix factorization network with semisupervised learning for SAR image change detection», ISPRS Journal of Photogrammetry and Remote Sensing, т. 160, p. 167–179, 2020.
241. Yan Y., «Convolutional neural networks based on augmented training samples for synthetic aperture radar target recognition», Journal of Electronic Imaging, т. 27, №2, 2018.
242. A. Krizhevsky, I. Sutskever, and G. Hinton, «Imagenet classification with deep convolutional neural networks», in Advances in neural information processing systems», Advances in neural information processing systems, p. 1097–1105, 2012.
243. K. Simonyan and A. Zisserman, «Very Deep Convolutional Networks for Large-Scale Image Recognition», Information and Software Technology, т. 51, №4, p. 769–784, 2014.
244. O. Kechagias-Stamatis, «Target recognition for synthetic aperture radar imagery based on convolutional neural network feature fusion», Journal of Applied Remote Sensing, т. 12, №4, 2018.
245. Deng J., Dong W., Socher R., Li L.-J., Kai Li, and Li Fei-Fei, «ImageNet: A large-scale hierarchical image database», в IEEE Conference on Computer Vision and Pattern Recognition, 2009.

246. Cui Z., Zhang M., Cao Z., and Cao C., «Image Data Augmentation for SAR Sensor via Generative Adversarial Nets», *IEEE Access*, т. 7, p. 42255–42268, 2019.

247. Sun Y., Wang Y., Liu H., Wang N., and Wang J., «SAR Target Recognition With Limited Training Data Based on Angular Rotation Generative Network», *IEEE Geoscience and Remote Sensing Letters*, 2019.

248. Fei Gao, Fei Ma, Jun Wang, Jinping Sun, Erfu Yang, Huiyu Zhou, «Semi-Supervised Generative Adversarial Nets with Multiple Generators for SAR Image Recognition», *Sensors*, т. 18, №8, 2018.

249. Planinšič P., Gleich D. «Temporal Change Detection in SAR Images Using Log Cumulants and Stacked Autoencoder», *IEEE geoscience and remote sensing letters*, т. 15, №2, pp. 297-301, 2018.

250. Lv N., Chen C., Qiu T., Sangaiah A.K., «Deep Learning and Superpixel Feature Extraction Based on Contractive Autoencoder for Change Detection in SAR Images», *IEEE Transactions on Industrial Informatics*, т. 14, №12, pp. 5530-5538, 2018.

251. Gong M., Yang H., Zhang P., «Feature learning and change feature classification based on deep learning for ternary change detection in SAR images», *ISPRS Journal of Photogrammetry and Remote Sensing*, т. 129, pp. 212-225, 2017.

252. De S., Pirrone D., Bovolo F., Bruzzone L., «A novel change detection framework based on deep learning for the analysis of multi-temporal polarimetric SAR images».

253. Luo B., Hu C., Su X., Wang Y., «Differentially Deep Subspace Representation for Unsupervised Change Detection of SAR Images», *Remote Sensing*, т. 11, №23, 2019.

254. Geng J., Wang H., Fan J., Ma X., «Change Detection of SAR Images Based on Supervised Contractive Autoencoders and Fuzzy Clustering».

255. Parikh H., Patel S., Patel V., «Classification of SAR and PolSAR images using deep learning: a review», *International Journal of Image and Data Fusion*.

256. Huang X., Nie X., Wu W., Qiao H., and Zhang B., «SAR target configuration recognition based on the biologically inspired model», *Neurocomputing*, т. 234, p. 185–191, 2017.

257. Liu F., Jiao L., Hou B., Yang S., «POL-SAR Image Classification Based on Wishart DBN and Local Spatial Information», IEEE transactions on geoscience and remote sensing, т. 54, №6, pp. 3293-3308, 2016.
258. Liu J., Gong M., Zhao J., Li H., Jiao L., «Difference representation learning using stacked restricted Boltzmann machines for change detection in SAR images», Soft Computing, т. 20, №12.
259. Samadi F., Akbarizadeh G., Kaabi H., «Change detection in SAR images using deep belief network: a new training approach based on morphological images», IET Image Processing, т. 13, №12, pp. 2255-2264, 2019.
260. Tanase R., Datcu M., Raducanu D., «A Convolutional deep belief network for polarimetric SAR data feature extraction» в IEEE International Geoscience and Remote Sensing Symposium, 2016.
261. Attioui S., Najah S., «Unsupervised change detection method in SAR images based on deep belief network using an improved fuzzy C-means clustering algorithm», IET Image Processing, т. 15, p. 974–982, 2021.
262. Chen, S., et al., «Target classification using the deep convolutional networks for sar images», Remote Sensing, т. 54, №8, p. 4806–4817, 2016.
263. Zhao Z., Jiao L., Zhao J., Gu J., Zhao J., «Discriminant deep belief network for high-resolution SAR image classification», Pattern Recognition, т. 61, pp. 686-701, 2017.
264. Geng J., Wang H., Fan J. and Ma X. «SAR Image Classification via Deep Recurrent Encoding Neural Networks», IEEE Transactions on Geoscience and Remote Sensing, т. 56, №4, pp. 2255-2269, 2018.
265. Wang L., Xu X., Dong H., Gui R., Yang R. and Pu F., «Exploring Convolutional Lstm for Polsar Image Classification», в IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium, Valencia, 2018.
266. Castro J.B., Feitosa R.Q., Happ P.N., «An hybrid recurrent convolutional neural network for crop type recognition based on multitemporal SAR image sequences», в IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium, 2018.
267. Kazemi S., Yonel B., Yazici B., «Deep Learning for Direct Automatic Target Recognition from SAR Data», в 2019 IEEE Radar Conference (RadarConf), 2019.
268. Wei G., Qingwen Q., Lili J., Ping Z., «A New Method of SAR Image Target Recognition based on AdaBoost Algorithm», в IGARSS 2008 – 2008 IEEE International Geoscience and Remote Sensing Symposium, 2008.

269. Chen K., Li Y., Xu X., Li Y., «A modified AdaBoost algorithm with new discrimination features for high-resolution SAR targets recognition», *IEICE Transactions on Information and Systems*, т. E98.D, № 10, pp. 1871-1874, 2015.

270. Ji X.X., Zhang G., «SAR Image Target Recognition with Increasing Sub-classifier Diversity Based on Adaptive Boosting», в *2014 Sixth International Conference on Intelligent Human-Machine Systems and Cybernetics*, 2014.

271. Min R., Quan H., Cui Z., Cao Z., Pi Y., «SAR Target Detection Using AdaBoost via GPU Acceleration», в *IEEE International Geoscience and Remote Sensing Symposium*, 2019.

272. Wen X.B., Zhang H., Jiang Z.T., «Multiscale Unsupervised Segmentation of SAR Imagery Using the Genetic Algorithm», *Sensors*, т. 8, № 3, pp. 1704-1711, 2008.

273. Bhanu B., Lin Y., «Genetic algorithm based feature selection for target detection in SAR images», *Image and Vision Computing*, т. 21, № 7, pp. 591-608, 2003.

274. С. О.П., «Применение генетических алгоритмов для распознавания изображений», *Искусственный интеллект*, № 4, pp. 516-520, 2002.

275. Hong-lei Z., Zhu-lin L., Yan W., «Road recognition in high resolution SAR image based on genetic algorithm», 2006.

276. Park J.I., Park S.H., Kim K.T., «New Discrimination Features for SAR Automatic Target Recognition», *IEEE geoscience and remote sensing letters*, т. 10, № 3, pp. 476-480, 2013.

277. Yang S., Wang M., Jiao L., «Radar target recognition using contourlet packet transform and neural network approach», *Signal Processing*, т. 89, № 4, pp. 394-409, 2009.

278. С. Д., *Алгоритмы эволюционной оптимизации*, М.: ДМК Пресс, 2020, p. 940.

2. РАДИОЛОКАЦИОННЫЕ СИСТЕМЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

За свою шестидесятилетнюю историю мониторинг земной поверхности в радиодиапазоне осуществлялся с использованием более чем сотни авиационных и космических платформ [1]. И если изначально это были устройства, основанные исключительно на принципах бокового обзора, то с течением времени методы совершенствовались, аппараты начали использовать когерентное накопление сигнала и технологию синтеза радиолокационной апертуры (РСА). Постепенно накапливался опыт обработки получаемых данных, а вместе с ним приходило осознание возможных направлений дальнейшего развития и улучшения качества РЛИ. С течением времени улучшалось пространственное разрешение, появились сенсоры, учитывающие поляризацию электромагнитных волн. Менялись и цели использования радиолокационных систем наблюдения – от военных разведывательных задач осуществлялся постепенный переход к гражданским миссиям, таким как мониторинг ледовой обстановки, наблюдения за природными и антропогенными объектами, прогнозирование чрезвычайных ситуаций и оценка последствий их ущерба и многое другое. Использование принципов интерферометрической обработки данных, полученных с различных витков орбиты, привело к появлению быстрого, практически полностью автоматизированного и сравнительно недорогого метода построения трехмерных моделей рельефа, создав альтернативу фотограмметрической стереообработке изображений оптического диапазона. С постепенным повышением пространственного разрешения круг потенциальных гражданских задач расширялся, что стимулировало запуск коммерческих космических систем дистанционного зондирования Земли (ДЗЗ). В настоящем разделе приведены наиболее распространенные коммерческие спутники ДЗЗ с указанием основных параметров и решаемых с их применением задач.

2.1. ALOS

ALOS (Advanced Land Observation Satellite) – серия японских спутников ДЗЗ [2<https://www.eorc.jaxa.jp/ALOS/en/aw3d30/index.htm>], включающая

два космических аппарата, владельцем которых является Японское аэрокосмическое агентство JAXA. Первый спутник ALOS (ALOS-1) был запущен в январе 2006 года и прослужил в общей сложности более 5 лет. Второй аппарат серии, ALOS-2, был выведен на орбиту в мае 2014 года и продолжил миссию своего предшественника. На сегодняшний день ALOS-2 – один из немногих коммерческих спутников ДЗЗ (наряду с SAOCOM-1A и SAOCOM-1B [3]), поставляющий радиолокационные изображения в L-диапазоне, что делает его незаменимым при решении ряда специфических задач.

Аппарат ALOS располагался на солнечно-синхронной орбите¹ высотой 692 км и наклоном² 93,2°. В основные задачи спутниковой системы входили круглосуточный и всепогодный мониторинг земной поверхности и океанов, создание и обновление топографических карт масштаба 1:25000 и мельче, контроль использования природных ресурсов, создание высокоточных цифровых моделей рельефа, мониторинг природных катастроф, а также решение различных научных и прикладных задач. В полезную нагрузку ALOS входило три сенсора: AVNIR-2 (Advanced Visible and Near Infrared Radiometer), PRISM (Panchromatic Remote-sensing Instrument of Stereo Mapping) и PALSAR (Phased Array L-band Synthetic Aperture Radar). AVNIR-2 представлял собой камеру, осуществлявшую съемку поверхности с полосой захвата до 70 км и пространственным разрешением до 10 м, обеспечивая получение многозональных космоснимков в четырех спектральных диапазонах (синий, зеленый, красный и ближний инфракрасный каналы). PRISM – картографическая стереокамера для формирования триплетов изображений в оптическом диапазоне, состоял из трёх панхроматических камер, обеспечивающих пространственное разрешение до 2,5 м. Наконец, PALSAR представлял собой PCA-датчик L-диапазона (рабочая длина волны 23 см), обеспечивающий разрешение на местности до 7 м. Схема космического аппарата с основным оборудованием приведена на рис. 2.1 [5].

¹ Солнечно-синхронная орбита – геоцентрическая орбита с такими параметрами, что объект, находящийся на ней, проходит над любой точкой земной поверхности приблизительно в одно и то же местное солнечное время [4].

² Наклонение – один из кеплеровских шести элементов орбиты, угол между плоскостью орбиты и базовой плоскостью [4]. Для искусственных спутников Земли в качестве базовой используется плоскость эклиптики.




Рис. 2.1. Схематическое изображение космического аппарата ALOS

Рассмотрим характеристики сенсора PALSAR более подробно. Сенсор PALSAR изменял угол визирования от 8 до 60° относительно направления в надир³ благодаря технологии фазированных антенных решеток с 80 модулями приема/передачи [6]. PALSAR поддерживал съемку в трех режимах работы – детальном (маршрутным) режиме (Fine), режиме сканирования (ScanSAR) и поляризационном режиме (Polarimetric). Детальный режим использовался наиболее часто, позволяя получать изображения с пространственным разрешением до 7 м, что на время начала работы спутника являлось рекордом среди РСА-систем. Именно этот режим использовался для получения данных для последующей интерферометрической обработки. Детальный режим разделялся на два подрежима, в первом из которых (Fine 1) формировались высокодетальные изображения в режиме одиночной поляризации (HH либо VV), во втором (Fine 2) – изображения более низкого пространственного разрешения в режиме двойной поляризации (HH + HV либо VV + VH). С помощью режима ScanSAR осуществлялось наблюдение местности с полосой захвата от 250 до 350 км с низким пространственным разрешением, он предназначался для глобального природного мониторинга. В этом режиме была возможна реализация только одиночной поляризации (HH либо VV). Поляризационный

³ Надир – направление, совпадающее действия силы гравитации для конкретной точки [7].

режим на момент разработки аппарата ALOS являлся экспериментальным и использовал как вертикальную, так и горизонтальную поляризации электромагнитных волн, обеспечивая полный поляризационный базис (HH + HV + VH + VV). Формат получаемых данных в зависимости от уровня обработки – CEOS/GeoTIFF, радиометрическое разрешение⁴ составляло 5 бит, периодичность съемки – 46 дней. Основные параметры приведенных режимов сенсора PALSAR приведены в табл. 2.1 [2].

Таблица 2.1

Основные режимы работы сенсора PALSAR спутника ALOS

Режим	Пространственное разрешение ⁵ , м	Полоса обзора ⁶ , км	Угол визирования, °
Fine 1	7	70	8–60
Fine 2	14	70	8–60
ScanSAR	100	350	18–43
Polarimetric	24	65	8–30

На рис. 2.2 представлен фрагмент изображения, полученного с помощью космического аппарата ALOS сенсором PALSAR в детальном режиме съемки Fine 1.

Спутник ALOS-2 выведен на солнечно-синхронную орбиту высотой 638 км и наклоном 97,9°. В отличие от своего предшественника, ALOS-2 не оснащен оптическими камерами наблюдения, представляя собой спутник ДЗЗ, выполняющий съемку исключительно в радиодиапазоне. На аппарате установлен PCA-датчик PALSAR-2, являющийся усовершенствованной версией сенсора PALSAR, а также система автоматической идентификации морских судов SPAISE2 и инфракрасная

⁴ Радиометрическое разрешение – количество градаций значений оттенков серого, соответствующих переходу от яркости абсолютно «черного» к абсолютно «белому», и выражается в количестве бит на пиксел изображения [8].

⁵ Здесь и далее имеется в виду наименьший интервал пространственной дискретизации в направлении азимута.

⁶ Здесь и далее имеется в виду наибольшее значение размеров местности под пятном засветки в направлении дальности.

камера CIRC [36]. PCA-датчик ALOS-2 осуществляет наблюдения в трех режимах: сверхвысокого разрешения (SpotLight), высокого разрешения (StripMap), а также в сканирующем режиме (ScanSAR).



Рис. 2.2. Фрагмент изображения, полученного с помощью датчика PALSAR

Территория села Ачхой-Мартан, Чеченская республика, 2010 год [8]

В режиме SpotLight, представляющем прожекторный режим, осуществляется съемка с пространственным разрешением до 1 м в режиме одиночной поляризации (HH, HV либо VV). StripMap является основным рабочим режимом спутника и разделяется на три подрежима: UltraFine, High Sensitive и Fine. Режим UltraFine обеспечивает съемку местности с пространственным разрешением до 3 м как в режиме одиночной (HH, HV либо VV), так и в режиме двойной поляризации (HH + HV либо VV + VH). В режиме High Sensitive возможно получение изображений земной поверхности с пространственным разрешением до 6 м в режиме одиночной (HH, HV либо VV) и двойной (HH + HV либо VV + VH) поляризации, а также в полном поляризационном базисе

(HH + HV + VH + VV), причем в последнем случае область охвата снимка окажется меньше. Аналогично, в режиме Fine возможно получить изображение земной поверхности с пространственным разрешением до 10 м во всех трех режимах поляризации, однако для полного поляризационного базиса охват местности будет меньше. Режим ScanSAR предназначен для получения изображений в низком пространственном разрешении при максимально возможном охвате местности. Различают два подрежима: стандартный (Normal) и расширенный (Wide). Для обоих режимов возможна как одиночная (HH, HV либо VV), так и двойная (HH + HV либо VV + VH) поляризация. Основные технические характеристики датчика PALSAR-2 приведены в табл. 2.2 [9].

Таблица 2.2

Основные режимы работы сенсора PALSAR-2 спутника ALOS-2

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
SpotLight	1	25	8–70
StripMap (UltraFine)	3	50	8–70
StripMap (High sensitive)	6	50 40 ⁷	8–70 20–40
StripMap (Fine)	10	70 30 ⁸	8–70 23,7
ScanSAR (N)	100	350	8–70
ScanSAR (W)	60	490	8–70

На рис. 2.3 представлен фрагмент изображения, полученного с помощью датчика PALSAR-2, режим съемки Fine.

В конце 2020 года на орбиту планируется вывести следующий аппарат миссии – ALOS-3 [10]. Спутник будет оснащен оборудованием, предназначенным для мониторинга исключительно в оптическом диапазоне:

⁷ При съемке в полном поляризационном базисе (HH + HV + VH + VV).

⁸ При съемке в полном поляризационном базисе (HH + HV + VH + VV).

стереокамера PRISM-2, обеспечивающая высокодетальную панхроматическую съемку местности с пространственным разрешением 0,8 м и шириной полосы обзора 50 км; мультиспектральный сканер HISUI (Hyperspectral Imager Suite), формирующий изображения в пяти спектральных диапазонах (видимые и ближний инфракрасный) с пространственным разрешением до 5 м.




Рис. 2.3. Фрагмент изображения, полученного с помощью датчика PALSAR-2. Вулкан Мерапи, остров Ява, Индонезия, 2014 год [9]

2.2. COSMO-SkyMed

COSMO-SkyMed (Constellation of small Satellites for the Mediterranean basin Observation, сокращенное название COS) – группировка четырех идентичных итальянских спутников, предназначенных для всепогодного мониторинга земной поверхности в военных и научных целях [11].

Отдельные аппараты принято обозначать как COSMO-SkyMed-1, -2, -3 и -4. В период с июня 2007 по ноябрь 2010 все четыре спутника были выведены на общую солнечно-синхронную орбиту высотой 619 км и наклоном $97,9^\circ$. Среди основных гражданских задач группировки COSMO-SkyMed можно выделить следующие: создание и обновление топографических карт масштаба 1:10 000 и мельче, получение высокоточных цифровых моделей рельефа⁹ (ЦМР), непрерывный мониторинг природных и антропогенных объектов, прогнозирование землетрясений и извержений вулканов.

Все аппараты созвездия в каждый момент находятся в одной плоскости, при этом возможны два варианта конфигурации спутников на орбите: номинальный и интерференционный [12]. В номинальном режиме все аппараты расположены на равных угловых расстояниях, составляющих 90° (рис. 2.4, а).




Рис. 2.4. Конфигурация аппаратов группировки COSMO-SkyMed (обозначены как S-1–S-4): а – номинальный режим; б – интерференционный режим, линия В – интерферометрический базис съемки. $\odot$ – восходящий узел орбиты¹⁰, $\otimes$ – нисходящий угол орбиты¹¹

⁹ Цифровая модель рельефа – цифровое представление земной поверхности как непрерывного явления, описывающее ее с определенной точностью. Для хранения цифровых моделей рельефа могут использоваться как растровые форматы, в этом случае представление является регулярным, так и векторные, тогда представление будет нерегулярным. Точность ЦМР принято характеризовать двумя параметрами: точность плановой привязки, показывающей, насколько хорошо ЦМР соответствует положению в определенной геодезической системе координат, и точность по высоте, характеризующую степень соответствия полученного продукта реальной картине местности.

¹⁰ Восходящий узел орбиты (северный) – точка, в которой движущееся по орбите тело пересекает условную плоскость в северном направлении [13].

¹¹ Нисходящий узел орбиты (южный) – точка, в которой движущееся по орбите тело пересекает условную плоскость в южном направлении [13].

Благодаря такой конфигурации, наблюдения за интересующей областью могут быть проведены до нескольких раз в день, что даёт возможность быстрого реагирования в случаях чрезвычайных ситуаций. Интерферометрический режим используется для получения трехмерных моделей местности, в этом случае два аппарата группировки располагаются на достаточно близком угловом расстоянии (рис. 2.4, б). В такой конфигурации осуществляется съемка одной и той же территории с двух спутников с несколько различающихся ракурсов, при этом расстояние между орбитами спутников выступает в роли интерферометрического базиса. Следует иметь в виду, что из-за различных погрешностей (запуск, движение в условиях атмосферы Земли, управление космическим аппаратом и т.д.) орбиты спутников совпадают только в некоторой степени, реально расстояние между ними составляет от сотен метров до единиц километров. Это расстояние между орбитами и образует интерферометрический базис, что позволяет использовать получаемые данные в задачах измерения рельефа. Последующая обработка полученных изображений позволяет восстановить трехмерную картину местности, а также исследовать ее изменения. Для ЦМР, получаемых с использованием данных аппаратов COSMO-SkyMed, относительная точность по высоте составляет от 3,8 м до 76 м в зависимости от режима съемки

Каждый из спутников COSMO-SkyMed оснащен PCA-датчиком Xдиапазона (рабочая длина волны 3,1 см), сам сенсор представляет собой фазированную решётку размерами 1,4×5,7 м [14]. Различают три основных режима работы: сверхвысокого разрешения (SpotLight), высокого разрешения (StripMap) и среднего/низкого разрешения (ScanSAR). Режим SpotLight (прожекторный режим) предназначен для выполнения съемки сверхвысокого пространственного разрешения. В нем различают два подрежима: SpotLight-1, который используется только решения для военных задач, и SpotLight-2, применяющийся в гражданских миссиях.

. Съемка осуществляется в одиночной поляризации (HH либо VV). Для режима StripMap (маршрутный режим) возможны две модификации – Himage, обеспечивающий съемку в более высокой детализации, и PingPong, с помощью которого формируются изображения с пространственным разрешением до 20 м. Для подрежима Himage возможна только одиночная поляризация (HH, HV, VH либо VV), для PingPong – двойная

(HH + VV, HH/HV либо VV + VH). Наконец, режим ScanSAR предназначен для получения изображений местности с максимально широким пространственным охватом. В нем также различают два подрежима – Wide и Huge с охватом местности 100 и 200 км соответственно. В режиме ScanSAR (сканирующий режим) возможна только одиночная поляризация (HH, HV, VH либо VV). Радиометрическое разрешение данных составляет 8 бит, скорость передачи данных на наземный сегмент – 310 Мбит/с, периодичность съемки в номинальной конфигурации – 10 часов. Основные параметры различных режимов работы сенсоров приведены в табл. 2.3.

Таблица 2.3

Режимы работы PCA-датчиков спутников группировки COSMO-SkyMed

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
SpotLight-2	1	10	20–60
StripMap (Himage)	5	40	18–60
StripMap (PingPong)	20	30	19–59
ScanSAR (Wide)	30	100	18–60
ScanSAR (Huge)	100	200	18–60

На рис. 2.5 приведен фрагмент изображения, полученного одним из аппаратов группировки COSMO-SkyMed в режиме высокого разрешения.

Для задач дополнения и постепенного замещения спутников группировки COSMO-SkyMed в настоящее время Итальянское космическое агентство ведет разработку аппаратов серии COSMO-SkyMed второго поколения – CSG [17]. Основное отличие аппаратов нового поколения заключается в том, что группировка будет состоять только из двух спутников – CSG-1 и -2, целевая аппаратура которых будет представлять собой улучшенные версии сенсоров спутников первого поколения. Орбита аппаратов второго поколения будет полностью совпадать с уже имеющейся.




Рис.2.5. Фрагмент изображения, полученного с помощью спутника COSMO-SkyMed (режим StripMap). Вершины горы Этна, Сицилия [12]

2.3. ERS

ERS (European Remote-Sensing Satellite) – серия из двух космических аппаратов Европейского космического агентства, предназначенных для мониторинга земной поверхности и атмосферы [15]. Спутник ERS-1 был выведен на солнечно-синхронную орбиту в июле 1991 года, прослужив в общей сложности почти 9 лет. Высота орбиты составляла 758 км, наклонение – $98,5^\circ$. Несмотря на то, что изначально бортовая аппаратура предназначалась для изучения атмосферы и водной поверхности, спустя некоторое время после запуска ERS-1 продемонстрировал свою эффективность в решении задач геологии, картографии и мониторинга растительного

покрова. Поэтому через три года после запуска ERS-1, в апреле 1995 года на ту же самую орбиту был запущен второй спутник серии ERS-2. По большей части этот аппарат был идентичен ERS-1, за исключением одного нового сенсора. Эксплуатация ERS-2 завершилась в сентябре 2011 года.

Рассмотрим более подробно инструменты аппарата ERS-1 [16]. Высотометр RA (Radar Altimeter) представлял собой одночастотный направленный в надир радиолокатор Ku-диапазона и предназначался для высокоточного измерения уровня морей и океанов, различных параметров ледяного покрова, а также скорости океанических ветров. Прибор ATSR-1 (Along-Track Scanning Radiometer) состоял из четырехканального инфракрасного радиометра и микроволнового излучателя, применялся для измерения температуры водной поверхности, а также температуры и влажности облаков. Наконец, датчик AMI представлял собой PCA-радиолокатор C-диапазона (рабочая длина волны 5,66 см) и предназначался для всепогодного мониторинга земной поверхности, обеспечивая формирование РЛИ с пространственным разрешением до 10 м.

Спутник ERS-2 был оснащен тем же самым оборудованием, что и ERS-1, однако также включал дополнительный инструмент – спектрометр ультрафиолетового и видимого диапазона GOME (Global Ozone Monitoring Experiment) [17], предназначавшийся для глобального мониторинга озонового слоя. Кроме того, совместное использование данных с обоих спутников позволяло решать задачи по обнаружению подвижек рельефа, обеспечивая субмиллиметровую точность согласно спецификации. Основная целевая аппаратура спутника ERS-2 представлена на рис. 2.6.

Рассмотрим подробнее инструмент AMI [16]. Фактически он представлял собой два независимых датчика: собственно, PCA-сенсор (AMI-SAR), выполнявший работу в двух режимах наблюдения – режиме изображения (Imaging mode) и волновом режиме (Wave Mode), а также радиолокационный рефлектометр (AMI-SCAT), предназначавшийся для сбора информации о скорости и направления ветров. Режим изображения использовался для формирования РЛИ высокого разрешения (от 10 до 30 м) и предоставлял собой традиционную маршрутную съемку. На рис. 2.7 приведен фрагмент изображения, полученного в данном режиме. Волновой режим датчика предназначался для получения двумерного изображения спектра морских и океанических волн. В этом режиме

сенсор осуществлял запись участков поверхности в рамках ширины кадра (5×5 км) с интервалом повторения каждые 200–300 км. Спектральное представление позволяло напрямую извлечь данные о размере волн и их ориентации в пространстве. Первоначально полученные данные использовались при прогнозировании погоды, однако, впоследствии оказались также применимы для обнаружения таких явлений, таких как пленки на поверхности, приповерхностные течения и лед. Размер антенны AMI-SAR составлял 10×1 м, радиометрическое разрешение данных – 5 бит. Оба режима сенсора использовали только одиночный тип поляризации (VV).




Рис. 2.6. Схематическое изображение космического аппарата ERS-2 [18]




Рис. 2.7. Фрагмент изображения, полученного с помощью сенсора AMI спутника ERS2 (режим Imaging mode). Атлантическое побережье северной Коста-Рики и южной Никарагуа [17]

Прибор AMI-SCAT включал три независимые боковые антенны для измерения скорости приповерхностных морских и океанических ветров (рис. 2.8). Принцип работы заключался в фиксации изменений ЭПР водной поверхности, обусловленной появлением ряби определенного типа при наличии ветров. Результаты съемки использовались в качестве опорных модельных данных при решении задач прогнозирования климатических изменений. Точность данных составляла 20° по направлению скорости и 2 м/с по величине скорости. Пространственное разрешение данных SCAT было достаточно низким и составляло 50 км. Следует отметить, что датчики SCAT и SAR не могли работать одновременно. Основные параметры режимов съемки представлены в табл. 2.4.




Рис. 2.8. Фрагмент РЛИ, полученных с помощью сенсора AMI (режим SCAT).
Атлантическое побережье северной Коста-Рики и южной Никарагуа [45]

Таблица 2.4

Основные режимы работы инструмента AMI спутников ERS

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Imaging mode	10	100	23 ¹²
Wave Mode	30	5	23
SCAT	5000	500	18–47

Несмотря на то, что спутники ERS-1 и ERS-2 в настоящий момент прекратили свою деятельность, полученные с их помощью данные до сих пор находят широкое применение в различных научных и прикладных

¹² После апреля 1992 спутник ERS-1 перешел в режим «разворотов и наклонов» (RTM Roll-tilt mode), что позволило увеличить угол визирования до 35°.

областях деятельности. Можно сказать, что миссия ERS положила начало регулярным наблюдениям поверхности Земли из космоса в радиодиапазоне в интересах Европейского космического агентства. Нарботки, использованные при проектировании аппаратов серии ERS, а также анализ эксплуатационного опыта легли в основу разработки последующих радиолокационных миссий, предназначенных для мониторинга территории Европы.

2.4. Envisat

Envisat – спутник Европейского космического агенства, предназначенный для исследования Земли из космоса [19]. По своей сути Envisat являлся преемником миссии спутников серии ERS. Он выведен на солнечно-синхронную полярную орбиту в марте 2002 года, апоцентр¹³ орбиты составлял 791 км, перицентр¹⁴ – 785 км, наклонение 98,6°. Основная миссия аппарата состояла в обеспечении непрерывности полетов европейских спутников ДЗЗ, предоставляя дополнительные данные для выполнения экологических исследований, в частности, исследования химического состава и динамики атмосферы, мониторинга гидрографической обстановки (температура и цвет воды, волны, гидрология), мониторинга сельского и лесного хозяйства, изучения снежных и ледовых покровов, а также создания цифровых моделей рельефа (в тандеме с данными, получаемыми с помощью аппаратов ERS-1,-2) и картографической продукции. В апреле 2012 года была потеряна связь с космическим аппаратом, после чего Европейское космическое агентство официально объявило о завершении миссии спутника.

На период с 2000 по 2010 годы Envisat являлся одним из самых крупных спутников ДЗЗ: суммарная масса аппарата составляла более 8000 кг, при этом он был оснащен девятью различными инструментами для мониторинга земной поверхности и атмосферы, включающими спектрометры MERIS, MIPAS и SCIAMACHY, сенсоры AATSR и GOMOS, радарный высотомер RA-2, радиометр MWR, система слежения DORIS и PCA-датчик ASAR [19] (рис. 2.9).

Спектрометр MERIS (MEdium Resolution Imaging Spectrometer) предназначался для выполнения съемки водной поверхности в видимом и ближнем инфракрасном диапазонах (длины волн от 390 до 1040 нм).

¹³ Апоцентр – наиболее удаленная от центрального тела точка орбиты небесного тела [4].

¹⁴ Перицентр – ближайшая к центральному телу точка орбиты небесного тела [4].

Основная задача заключалась в мониторинге цвета воды океанов с целью последующего анализа ее химического состава. Сенсор AATSR (Advanced Along Track Scanning Radiometer) представлял собой улучшенную версию инструментов ATSR космических аппаратов миссии ERS и использовался для измерения температуры морской поверхности с точностью до 0,3 К. Полученные данные в основном использовались в качестве опорных при прогнозировании климатических измерений, также среди вторичных задач сенсора следует отметить мониторинг состава и динамики растительности. Радар RA-2 (Radar Altimeter 2) осуществлял надирные наблюдения в Ku- и S-диапазонах и преимущественно применялся для изучения океанического рельефа, также осуществлял наблюдения за ледовым покрытием. Радиометр MWR (Microwave Radiometer) предназначался для измерения процентного содержания водяного пара в атмосфере. Микроволновая следящая система DORIS (Doppler Orbitography and Radiopositioning Integrated by Satellite) выполняла задачу по позиционированию спутника на орбите, при этом заявленная точность определения координат составляла 10 см. Сенсор GOMOS (Global Ozone Monitoring by Occultation of Stars) осуществлял наблюдение за изображениями звёзд через толщу высоких слоев атмосферы¹⁵. Сравнивая цвет полученных образов с эталонными изображениями можно было сделать выводы о процентном соотношении и пространственном распределении различных атмосферных компонент. Фурье-спектрометр среднего инфракрасного диапазона MIPAS (Michelson Interferometer for Passive Atmospheric Sounding) применялся для измерения давления и температуры различных соединений (диоксид азота NO₂, закись азота N₂O, метан CH₄, азотная кислота HNO₃, озон O₃) в стратосфере. Спектрометр SCIAMACHY (SCanning Imaging Absorption spectroMeter for Atmospheric CHartographY) применялся для построения карт распределения различных газов и аэрозолей в тропосфере и стратосфере. Наконец, ASAR (Advanced Synthetic Aperture Radar) представлял собой PCA-датчик С-диапазона (рабочая длина волны 5,6 см).

¹⁵ Обозначенный метод измерения основан на приеме покрытия – явления, во время которого, с точки зрения наблюдателя из определённой точки, одно небесное тело проходит перед другим небесным телом, заслоняя его полностью или частично [20].

Сенсор ASAR осуществлял съемку в пяти различных режимах: режим изображения (Image Mode), режим переменной поляризации (Alternating Polarisation), полосовой режим (Wide Swath), режим глобального мониторинга (Global Monitoring) и волновой режим (Wave Mode).




Рис. 2.9. Целевая аппаратура спутника Envisat [20]

Режим изображения использовался для получения РЛИ высокого пространственного разрешения (до 30 м) и являлся наиболее часто используемым для спутника Envisat. Полосовой режим был сканирующим с возможностью получения изображения среднего пространственного разрешения с полосой обзора до 405 км. В режиме глобального мониторинга осуществлялось формирование изображений низкого разрешения (1 км), применяющихся для решения задач наблюдения ледовой и водной поверхностей, лесных вырубок, а также анализа влажности почв. Волновой режим представлял собой прожекторный режим съемки, формирование данных происходило с интервалом между кадрами 100 км,

а пространственное разрешение составляло до 10 м. Режим переменной поляризации позволял получать изображения земной поверхности в двойной поляризации (HH + VV, HH + HV, VV + VH). Остальные четыре режима позволяли осуществлять съемку только в режиме одиночной поляризации (HH либо VV). Скорость передачи всех данных составляла 100 Мбит/с, радиометрическое разрешение 8 бит, периодичность съемки от 2,5 до 35 дней [21]. Технические параметры режимов работы сенсора приведены в табл. 2.5. На рис. 2.10 приведен фрагмент изображения, полученного с помощью датчика ASAR космического аппарата Envisat в режиме изображения.

Таблица 2.5

Основные режимы работы сенсора ASAR спутника Envisat

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол в изирования, °
Image Mode	30	105	15–45
Wave Mode	10	10	15–45
Global Monitoring	1000	1000	17–42
Wide Swath	150	405	17–42
Alternating Polarisation	30	105	15–45




Рис. 2.10. Фрагмент изображения, полученного с помощью сенсора ASAR спутника Envisat. Северный берег Аляски (нижний левый угол) и морской лед в море Бофорта [22]

2.5. RADARSAT

RADARSAT – канадская программа спутников ДЗЗ, разработанная для мониторинга земной поверхности в радиодиапазоне, а также решения задач наблюдения за климатом. Владелец аппаратов является Канадское космическое агентство. Первый из спутников программы, RADARSAT-1, был выведен на солнечно-синхронную орбиту (апоцентр 821 км, перигей 793 км, наклонение $98,6^\circ$) в ноябре 1995 года [23]. В последствии было установлено, что данные космического аппарата могут быть применимы во многих научных и практических отраслях, таких как контроль качества агрономических культур, мониторинг гидрографической и ледовой обстановок, растительности, картография, океанология и геология. Основным инструментом RADARSAT-1 являлся PCA-сенсор Сдиапазона (рабочая длина волны 5,6 см), обеспечивающий получение изображений с пространственным разрешением до 8 м. Следует отметить, что на момент запуска спутника обозначенный сенсор был первым, поддерживающим возможность изменения угла визирования за счет использования антенных фазированных решеток. RADARSAT-1 прекратил передачу данных в марте 2013 года, прослужив в общей сложности более 17 лет.

Следующим аппаратом миссии становится RADARSAT-2, выведенный на ту же орбиту в декабре 2007 года [23] и продолжающий сбор данных по настоящее время. Характеристики PCA-сенсора второго спутника миссии во многом превосходят параметры своего предшественника, в том числе обеспечивают более высокое пространственное разрешение (до 3 м) и возможность выбора типа поляризации импульса. Кроме того, на аппарате реализована возможность съемки областей как с левой, так и с правой стороны относительно траектории полета, что позволяет увеличить временное разрешение поставляемых данных. Применение его снимков включает картирование морских льдов и геологических пород, наблюдение за сельскохозяйственными культурами, контроль загрязнений окружающей среды и береговую охрану территории Канады.

Наконец, группировка RADARSAT Constellation Mission (RCM) представляет собой систему из трех идентичных спутников, продолжающих задачи аппаратов более ранних поколений, а также предлагающих широкий спектр всевозможных задач практического использования за счет уменьшения интервалов между съемками [24]. В перспективе планируется

увеличить количество аппаратов до шести. Спутники выведены на общую солнечно синхронную орбиту в июне 2019 года, высота орбиты составила 600 км, наклонение $97,74^\circ$. Угловое расстояние между аппаратами одинаковое и составляет 120° (рис. 2.11). Благодаря такой конфигурации на орбите использование RCM позволяет просматривать до 90 % земной поверхности с периодичностью в один день, за счет чего заказчики могут получать необходимую информацию практически в реальном режиме времени. Дополнительно к PCA-датчику каждый из аппаратов оснащён автоматической системой идентификации судов (AIS), которая может использоваться параллельно с основным сенсором. Сравнительные характеристики аппаратов миссии RADARSAT приведены в табл. 2.6 [24].




Рис. 2.11. Орбитальная конфигурация аппаратов группировки RCM

Таблица 2.6

Сравнительные характеристики аппаратов миссии RADARSAT

Параметр	RADARSAT-1	RADARSAT-2	RCM
Дата запуска	4.11.1995	14.12.2007	12.06.2019
Полное покрытие	2–3 дня	2–3 дня	ежедневное
Масса, кг	2750	2200	1400 (каждый аппарат)
Размеры антенны, м	15×1,5	15×1,5	6,75×1,38
Размеры солнечных панелей	2,21×1,32 м (две панели)	3,73×1,8 м (две панели)	2,21,7 м (одна панель)
Направление обзора	Правый	Правый и левый	Правый
Поляризация	Одиночная (HH)	Одиночная, двойная, полный базис	Одиночная, двойная, полный базис
Средняя высота, км	800	800	600

Рассмотрим более подробно сенсоры спутников миссии RADARSAT. РСА-датчик космического аппарата RADARSAT-1 осуществлял съемку с использованием только одиночного типа поляризации (HH), при этом угол визирования изменялся в пределах от 10 до 59° с правой стороны относительно траектории движения спутника. Принято различать пять основных режимов работы сенсора: маршрутный (Fine), маршрутный с накоплением (Standart), маршрутный широкозахватный (Wide), маршрутный с увеличенным углом визирования (Extended) и сканирующий (ScanSAR) [25]. Режим работы Fine представлял собой режим по умолчанию и обеспечивал формирование РЛИ с пространственным разрешением до 8 м.

Маршрутный режим с накоплением отличался от режима Fine тем, что в нем применялось накопление сигнала, что позволяло уменьшить спекл-шум на итоговом изображении. Широкозахватный маршрутный режим подразделялся на два подрежима: Wide 1 и Wide 2, которые отличались углами визирования и, как следствие, шириной полосы обзора. Маршрутный режим с увеличенным углом визирования также подразделялся на два подрежима – Extended High и Extended Low, позволяющими

осуществлять наблюдения на экстремально больших (High) и экстремально малых (Low) углах визирования. В сканирующем режиме также принято различать два подрежима – сканирующий широкий (Wide) и сканирующий узкий (Narrow) режимы съемки. Отличие между ними заключалось в различной ширине полосы обзора приблизительно в два раза (3:5), и, соответственно, в различном пространственном разрешении (1:2). Основные технические характеристики режимов съемки приведены в табл. 2.7.

Данные космического аппарата RADARSAT-1 нашли широкое применение в самых разных отраслях науки и техники, в том числе использовались в проекте АММ [23], результатом работы которого стало создание изображения высокого разрешения (25 м) территории Антарктиды (рис. 2.12). Полученный продукт содержит детальную информацию о морфологии ледяного покрова, выхода пород, информацию о береговой линии и прочие характеристики, которые до сих пор используются в качестве опорных для оценки изменений полярного ледяного покрова.

Как отмечалось выше, сенсор спутника RADARSAT-2 отличается большей гибкостью в управлении углом визирования (и, соответственно, большей полосой обзора) и возможностью выбора режима поляризации [26]. Помимо режимов съемки, имеющихся у аппарата RADARSAT-1 (табл. 2.7), RADARSAT-2 обеспечивает съемку в двенадцати принципиально новых режимах, а именно, сверхвысокого разрешения (SpotLight A), детальный маршрутный (Ultra Fine), широкозахватный детальный маршрутный (Wide Ultra Fine), маршрутный с накоплением (Multi-look Fine), широкозахватный маршрутный с накоплением (Wide Multi-look Fine), улучшенный маршрутный (Extra Fine), широкозахватный маршрутный (Wide Fine), широкозахватный маршрутный с полным поляризационным базисом (Wide Fine Quad), стандартный маршрутный с полным поляризационным базисом (Standard Quad), широкозахватный стандартный маршрутный с полным поляризационным базисом (Wide Standard Quad), режим наблюдения за океаном (Ocean Surveillance), режим обнаружения кораблей (Ship Detection) [27]. Режим сверхвысокого разрешения представляет собой прожекторный режим съемки, обеспечивающий формирование РЛИ с пространственным разрешением до 1,5 м. В этом режиме доступна только одиночная поляризация (HH, VV, HV либо VH). Фрагмент изображения земной поверхности, полученного в этом режиме, приведен на рис. 2.13.




Рис. 2.12. Изображение территории Антарктики, составленного по более чем 8000 космоснимков аппарата RADARSAT-1 (маршрутные режимы съемки) [23]

Таблица 2.7

Основные режимы съемки PCA-сенсора спутника RADARSAT-1

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Fine	8	45	37–48
Standard	25	100	20–49
Extended High	25	75	50–60
Extended Low	25	170	10–23
Wide 1	30	165	20–31
Wide 2	30	150	31–39
ScanSAR Narrow	50	305	20–40
ScanSAR Wide	100	510	20–49




Рис. 2.13. Фрагмент изображения, полученного с помощью PCA-датчика RADARSAT-2 (прожекторный режим съемки) [23]

Еще девять новых режимов представляют собой различные модификации маршрутного режима. С использованием стандартного маршрутного режима съемки (Standart) можно получить космоснимки с пространственным разрешением до 15 м, тогда как маршрутный режим (Fine) позволяет сформировать изображения с пространственным разрешением до 6,5 м, но с меньшей полосой обзора (100 км против 50 км). В детальном маршрутном режиме возможно получение изображений с пространственным разрешением до 3 м, широкозахватный детальный маршрутный режим обеспечивает формирование РЛИ с такими же параметрами, но в увеличенной (до 50 км) полосе обзора. Для обоих режимов доступна только одиночная поляризация (HH, VV, HV либо VH). Фрагмент изображения, полученный в детальном маршрутном режиме, показан на рис. 2.14. Маршрутный режим съемки с накоплением позволяет достичь снижения шума на изображении без потери в пространственном разрешении, составляющем 5 м.

Соответственно, широкозахватный маршрутный режим съемки с накоплением позволяет получить РЛИ того же качества, но с увеличенной (до 90 км) полосой обзора. Съемка в обоих режимах осуществляется только в режиме одиночной поляризации (HH, VV, HV либо VH). Улучшенный маршрутный режим позволяет получать изображения с полосой охвата, как и в широкозахватном маршрутном режиме (до 160 км), но с более высоким пространственным разрешением (до 5 м), тогда как в широкозахватном маршрутном режиме формируются изображения с пространственным разрешением 8 м как при одиночной (HH, VV, HV либо VH), так и в двойной (HH + HV либо VV + VH) поляризациях. Использование двойной поляризации возможно при съемке в маршрутном, маршрутном с накоплением, широкозахватном и широкозахватном маршрутном режимах. Маршрутные режимы с отметкой Quad (широкозахватный маршрутный, маршрутный с накоплением и расширенный маршрутный с накоплением) позволяют получать РЛИ в полном поляризационном базисе (HH + VV + HV + VH).



Рис. 2.14. Фрагмент изображения, полученного с помощью PCA-датчика RADARSAT-2 (детальный маршрутный режим) [23]

Режимы наблюдения за океаном и обнаружения кораблей относятся к сканирующему типу съемки и предназначены для фиксации образов кораблей на обширных водных поверхностях. Из-за специфики процедуры обнаружения морских судов для обоих режимов применяется усиленное сжатие по азимуту в ближних каналах дальности и подавление шумов на больших наклонных дальностях.

При съемке в режиме обнаружения кораблей осуществляется самая высокая степень сжатия данных из возможных, поэтому для формируемых РЛИ характерен высокий уровень шума, благодаря анализу которого становится возможным определить небольшие суда в рамках существенной площади кадра (рис. 2.15). В этом режиме возможно осуществлять съемку во всех режимах одиночной поляризации (HH, VV, HV либо VH), однако в виду преимущественно горизонтальной ориентации судов в пространстве предпочтительным является тип поляризации HH (см. часть 2, раздел VI). Пространственное разрешение формируемых изображений составляет 30 м. Режим наблюдения за океаном подобен режиму обнаружения кораблей, однако в этом случае соблюдается баланс между эффективностью поиска целей и шумовыми компонентами для возможности применения получаемых данных в иных практических приложениях. В этом режиме возможно применение как одиночной (HH, VV, HV либо VH), так и двойной (HH + HV либо VV + VH) поляризации. При решении задач обнаружения морских судов на водной поверхности предпочтительнее использовать двойную поляризацию типа (HH + HV), тогда как для таких задач, как определение параметров приповерхностных ветров и обнаружение нефти на поверхности воды более полезной оказывается поляризация типа (VV + VH). Как для режима обнаружения кораблей, так и для режима наблюдения за океаном характерна максимально широкая полоса охвата (до 510 км). Следует отметить, что PCA-датчик спутника RADARSAT-2 обеспечивает съемку в сканирующем широком и сканирующем узком режимах работы как при одиночной (HH, VV, HV либо VH), так и при двойной (HH + HV либо VV + VH) поляризациях.

Наконец, спутники группировки RCM являются продолжением миссии RADARSAT, дополняя и расширяя возможности своих предшественников за счет сокращения времени между съемками одной и той же местности. Полезная нагрузка каждого из аппаратов состоит из идентичных

РСА-датчиков, интегрированных автоматизированной системой идентификации судов (AIS) [28]. Каждый из сенсоров осуществляет съемку в восьми режимах работы: сверхвысокого разрешения (Spotlight), высокого разрешения (High Resolution), очень высокого разрешения (Very High Resolution), полного поляризационного базиса (Quad-Polarization), среднего разрешения (Medium Resolution), низкого разрешения (Low Resolution), низкошумного (Low Noise), обнаружения кораблей (Ship Detection).




Рис. 2.15. Фрагмент изображения, полученного с помощью РСА-датчика RADARSAT-2 (режим обнаружения кораблей) [23]

В табл. 2.8 приведены основные параметры режимов съемки аппарата RADARSAT-2.

Режим сверхвысокого разрешения является прожекторным и обеспечивает фиксацию земной поверхности с детализацией до 1 м. Режимы высокого разрешения, очень высокого разрешения и полного поляризационного базиса представляют собой вариации маршрутного режима, обеспечивающих формирование РЛИ с пространственным разрешением от 3 до 9 м, причем режим Quad-Polarization осуществляет съемку в полном поляризационном базисе. Режим среднего разрешения подразделяется на три подрежима,

обеспечивающих пространственное разрешение изображений, равное 16, 30 и 50 м. Первые два подрежима по технической реализации относятся к маршрутному режиму съемки, тогда как последний – к сканирующему.

Таблица 2.8

Режимы съемки PCA-сенсора спутника RADARSAT-2

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
SpotLight A	1,5	18	20–50
Ultra Fine	3	20	30–50
Wide Ultra Fine	3	50	30–50
Multi-look Fine	5	50	29–50
Wide Multi-look Fine	5	90	29–50
Extra Fine	5	160	22–49
Fine	6,5	50	30–50
Fine Quad	8	25	18–49
Wide Fine	8	160	20–45
Wide Fine Quad	9	50	18–42
Wide	10	170	18–45
Extended High	10	80	49–60
Standard Quad	12	25	18–49
Wide Standard Quad	12	50	18–42
Standart	15	100	20–52
Extended Low	15	170	10–23
Ship Detection	35	510	35–56
ScanSAR Narrow	50	305	20–47
Ocean Surveillance	50	510	20–50
ScanSAR Wide	100	510	20–49

Также к сканирующему режиму съемки относятся режимы низкого разрешения, обнаружения кораблей и низкошумный режим. Как и для РСА-датчика аппарата RADARSAT-2, для режима обнаружения кораблей характерно максимальное увеличение амплитуды отклика от цели по отношению к фоновому шуму, включающему две разные составляющие: тепловой шум и помехи, вызванные возмущением водной поверхности. При съемке местности в низкошумном режиме используется несколько более широкая диаграмма направленности по сравнению с прочими сканирующими режимами, что позволяет осуществить накопление сигнала при сохранении величины пространственного разрешения. Данные, полученные в этом режиме, находят широкое применение при решении задач мониторинга нефти и льда на водной поверхности [29]. Фрагмент изображения, полученного в низкошумном режиме, приведен на рис. 2.16. Для всех указанных режимов, за исключением сверхвысокого разрешения, низкошумного и обнаружения кораблей, возможна съемка как при одиночной (HH, VV, HV либо VH), так и при двойной (HH + HV, VV + VH либо HH + VV) поляризациях, тогда как для отмеченных режимов в случае применения двойной поляризации возможно только использование комбинаций поляризации волны HH + HV либо VV + VH. Основные параметры режимов съемки аппаратов RCM представлены в табл. 2.9.




Рис. 2.16. Фрагмент изображения, полученного с помощью группировки спутников RCM (низкошумный режим). Изображение морского льда в проливе Дэвиса и побережье острова Баффин, Нунавут, июнь 2019 года [24]

Таблица 2.9

Режимы съемки РСА-сенсоров спутников группировки RCM

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Spotlight	1	20	19–54
Very High Resolution	3	20	18–54
High Resolution	5	30	19–54
Quad-Polarization	9	20	19–54
Medium Resolution 1	16	30	20–47
Medium Resolution 2	30	125	21–47
Medium Resolution 3	50	350	19–58
Low Resolution	100	500	19–54
Low Noise	100	350	19–58
Ship Detection	25	600	35–56

2.6. Sentinel

Sentinel – семейство спутников дистанционного зондирования Земли Европейского космического агентства, предназначенных для контроля землепользования, мониторинга растительности и водных ресурсов, для операций по ликвидации последствий стихийных бедствий. Первая миссия, Sentinel-1, состоит из двух аппаратов, обозначаемых как –1А и –1В, расположенных на общей солнечно-синхронной орбите высотой 693 км и наклоном 98,2° в противоположных орбитальных точках [30]. Спутник Sentinel-1А запущен в апреле 2014, Sentinel-1В – в апреле 2016 года. Данные миссии Sentinel-1 находят широкое применение в решении самых разных задач, в частности, регулярные наблюдения моря и суши, мониторинг последствий природных бедствий, оценка влажности почвы, а также имеют различные экономические приложения. Оба аппарата оснащены РСА-датчиком С-диапазона (рабочая длина волны 5,6 см) правого бокового обзора, представляющего собой фазированную антенную решетку.

В настоящее время ведутся работы над продолжением миссии в виде аппаратов Sentinel-1C и -1D, даты запуска которых пока не определены.

Каждый из сенсоров Sentinel-1 поддерживает четыре режима работы: маршрутный (Stripmap), интерферометрический (Interferometric Wide Swath), сверхширокий (Extra-Wide Swath) и волновой (Wave Mode) (табл. 2.10). Данные, полученные в маршрутном режиме, представляют собой типичные РЛИ с пространственным разрешением до 5 м. Интерферометрический режим обеспечивает получение данных высокого разрешения, наиболее частое применение которых заключается в формировании трехмерных цифровых моделей рельефа и обнаружения его изменений. Этот же режим съемки используется по умолчанию при мониторинге поверхности суши. Режим сверхширокого обзора (сканирующий режим) предназначен для оперативных наблюдений морских приполярных территорий, в этом случае формируются РЛИ среднего пространственного разрешения, которые также могут быть использованы в задачах интерферометрии. Волновой режим применяется для определения направления, высоты и длины волны в открытом океане. При использовании маршрутного, интерферометрического и сверхширокого режимов возможны наблюдения как в одиночной (HH либо VV), так и в двойной поляризации (HH + HV, VV + VH), данные которой оказались особенно полезны в решении задач по классификации типов морского льда. В волновом режиме доступна съемка только с применением одиночной поляризации (HH либо VV).

Таблица 2.10

Основные режимы работы РСА-сенсоров спутников Sentinel-1

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Stripmap	5	80	18–47
Interferometric Wide Swath	20	250	29–46
Extra-Wide Swath	100	400	19–47
Wave Mode	20	20	22–38

Следующим поколением спутников миссии Sentinel становятся аппараты –2А (запуск июнь 2015 года) и –2В (запуск март 2017 года), предназначенные для контроля использования земных угодий, растительности, сельскохозяйственных и водных ресурсов в рамках программы Коперник (Copernicus) [32, 33]. Как и в случае спутников Sentinel-1, космические аппараты располагаются на одной солнечно-синхронной орбите (высота 786 км, наклонение $98,6^\circ$) на расстоянии 180° друг от друга. В отличие от своих предшественников, аппараты Sentinel-2 осуществляют съемку в оптической и инфракрасной зонах спектра с пространственным разрешением от 10 до 60 м и шириной обзора 290 км. В настоящий момент ведутся работы по созданию спутников Sentinel-2С и Sentinel-2D, которые будут выведены на орбиту после 2021 года в целях поддержания действующей программы.

На рис. 2.17 представлен фрагмент изображения, полученного с применением РСА-датчика одного из аппаратов миссии Sentinel-1.




Рис. 2.17. Фрагмент изображения, полученного с помощью группировки спутников Sentinel-1 (режим Interferometric Wide Swath). Юго-запад Стамбула, Турция, 2018 год [31]

Наконец, третьим этапом космической миссии Sentinel становятся спутники –3А и –3В. Названные аппараты являются улучшенными версиями спутников Envisat и ERS-2. Как и их предшественники, Sentinel-3А и –3В располагаются на общей солнечно-синхронной орбите высотой

815 км и наклонением $98,7^\circ$ [34]. Вывод на орбиту аппарата Sentinel-3A произошел в феврале 2016 года, Sentinel-3B – в апреле 2018 года. Среди важнейших задач миссии Sentinel-3 стоит отметить следующие: топография водной поверхности, измерение температуры воды и суши, а также мониторинг окружающей среды и климатический контроль. Из полезной нагрузки на борту каждого из спутников установлено четыре различных датчика (рис. 2.18): температурный радиометр SLSTR (Sea and Land Surface Temperature Radiometer), измеряющий температуру поверхности воды с точностью до 0,3 К; спектрометр OLCI (Ocean and Land Colour Instrument), представляющий собой усовершенствованную версию сенсора MERIS аппарата Envisat и формирующий изображения земной поверхности в среднем пространственном разрешении в 21 спектральном канале; двухчастотный радиолокационный высокотометр SRAL (Synthetic Aperture Radar Altimeter), работающий в Ku- и C-диапазонах и предназначенный для создания топографических карт поверхности океанов и морей, а также ледовых поверхностей. Сенсор предназначен для работы в двух режимах: высокого (SAR) и низкого (LRM) пространственных разрешений.




Рис. 2.18. Целевая аппаратура спутников Sentinel-3 [34]

В октябре 2017 года на орбиту выведен аппарат Sentinel-5 Precursor (Sentinel-5P), предназначенный для мониторинга атмосферных загрязнений [35]. Основным инструментом спутника является спектрометр TROPOMI (TROPOspheric Monitoring Instrument), представляющий собой совместную разработку Европейского космического агентства и правительства Нидерландов. Основная задача спутника заключается в осуществлении измерений химических компонент воздуха с высоким пространственно-временным разрешением. Полученные данные используются для определения качества воздуха, мониторинга озонового слоя, а также служат модельной основой при прогнозировании климатических изменений.

В настоящее время также ведутся работы по реализации миссий Sentinel-4, Sentinel-5 и Sentinel-6. Основной задачей спутников Sentinel-4 будет мониторинг химического состава атмосферы, а именно измерение процентного содержания таких соединений, как озон (O_3), диоксид азота (NO_2), диоксид серы (SO_2), формальдегид ($HCHO$), а также оценка оптической толщины аэрозолей [36]. Из полезной нагрузки на аппарате будут установлены спектрометры UVN (Ultraviolet Visible Near-infrared), охватывающие диапазоны от ультрафиолетового до ближнего инфракрасного, и тепловизоры IRS (Infrared Sounder), позволяющие получить трехмерное распределение температуры атмосферы и водяного пара. В настоящее время вывод на орбиту аппаратов Sentinel-4 запланирован на 2023 год. Аппаратура спутника Sentinel-5 (запуск в 2021 году) в целом будет аналогична Sentinel-4 за тем исключением, что он позволит оценивать количественное содержание соединений CO , CH_4 и O_3 с ежедневным глобальным покрытием [37]. Основная задача спутников миссии Sentinel-6 будет заключаться в высотометрии уровня мирового океана, запуск аппаратов запланирован на конец 2020 (–6 А) и начало 2026 (–6 В) гг.

Следует отметить, что некоторые из космических снимков и производных данных, полученные с аппаратов миссий Sentinel, находятся в свободном доступе на официальном сайте проекта Коперник [38].

2.7. TerraSAR-X

TerraSAR-X (иногда обозначается как TSX) – спутник Немецкого аэрокосмического центра (DLR), запущенный в июне 2007 года [39]. Орбита аппарата солнечно-синхронная, высота в апогее составляет 516 км, высота в перигее – 514 км, наклонение – $97,4^\circ$. Движение спутника по орбите

осуществляется вдоль линии терминатора таким образом, что аппарат всегда обращен в сторону Солнца, что обеспечивает оптимальное накопление энергии через солнечные батареи. Основным инструментом TerraSAR-X является радиолокатор с синтезированной апертурой Хдиапазона (рабочая длина волны 3,1 см) размером 5×0,8 м, позволяющий осуществлять съемку земной поверхности с пространственным разрешением до 1 м, являясь по сути третьим аппаратом (после COSMO-SkyMed и RADARSAT-2), обеспечивающим формирование радиолокационных изображений со сверхвысоким разрешением. Среди основных задач спутника следует отметить составление и обновление топографических карт масштаба до 1:25000, мониторинг окружающей среды и экологической обстановки, а также обнаружение подвижек рельефа. Для спутника доступна возможность левой и правой боковой съемки, а также съемка в нескольких типах поляризации. Отличительной особенностью аппарата TerraSAR-X является короткое время реагирования, позволяющее осуществить выбор режима съемки и тип поляризации в течение трех секунд.

Рассмотрим подробнее PCA-сенсор спутника TerraSAR-X. Датчик поддерживает три основных режима работы: SpotLight, StripMap и ScanSAR (табл. 2.11). Режим SpotLight (прожекторный режим) предназначен для получения высоко детальных изображений с пространственным разрешением до 0,24 м. В нем принято различать три подрежима: собственно, SpotLight, High Resolution SpotLight, для которого также возможны реализации в одиночной (VV либо HH), либо двойной (HH + VV) поляризации, и Staring SpotLight, в котором антенна фиксируется на одной сцене на протяжении длительного времени синтеза, благодаря чему и формируется РЛИ сверхвысокого пространственного разрешения. Режим StripMap (маршрутный режим) аналогичен режиму датчика аппарата ERS-1 и является основным рабочим режимом для TerraSAR-X. В нем возможна реализация как одиночной поляризации (VV либо HH), так и двойной (HH + VV, HH + HV, либо VV + VH). Режим ScanSAR (сканирующий режим) также подразделяется на два подрежима: собственно, ScanSAR и Wide ScanSAR. Оба они предназначены для глобального мониторинга земной поверхности в низком пространственном разрешении и с широкой полосой захвата. Оба подрежима поддерживают только

одинокую поляризацию, причем для ScanSAR возможна реализация VV либо HH, для Wide ScanSAR – VV, HH, HV либо VH [40]. На рис. 2.19 приведен фрагмент изображения, полученного со спутника TerraSAR-X.

Таблица 2.11

Основные режимы работы PCA-датчика спутника TerraSAR-X

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Staring SpotLight	0,24 ¹⁶	4	20–45
HighRes SpotLight	1,1	10	20–55
SpotLight	1,7	10	20–55
StripMap	3,3 ¹⁷ /6,6 ¹⁸	30/15	20–45
ScanSAR	18,5	100	20–45
Wide ScanSAR	40	270	16–49




Рис. 2.19. Фрагмент изображения, полученного с помощью спутника TerraSAR-X (режим StripMap). Порт города Керчь, Россия [41]

2.8. TanDEM-X

TanDEM-X – спутник-компаньон космического аппарата TerraSAR-X, являющийся его практически полной идентичной копией. Выведен на солнечно-синхронную орбиту в июне 2010 года. Средняя высота

¹⁶ Только для военных миссий.

¹⁷ В режиме одиночной поляризации.

¹⁸ В режиме двойной поляризации.

орбиты составляет 515 км, наклонение $97,4^\circ$, причем восходящий узел орбиты подобран таким образом, чтобы в каждый момент времени аппараты TerraSAR-X и TanDEM-X находились на расстоянии от 200 м до 3 км (в среднем 250–500 м), образуя оптимальный интерферометрический базис [42]. На рис. 2.20 представлен снимок с Земли обоих спутников, расстояние между которыми в момент съемки составило 70 угловых секунд.




Рис. 2.20. Космические аппараты TerraSAR-X и TanDEM-X (фото Марко Лангбрука, Лейден, Нидерланды, экспозиция кадра 10 с)

Задачи аппарата TanDEM-X схожи с задачами его предшественника. Среди основных из них следует отметить наблюдение и оценку динамики таяния ледников, мониторинг зон вечной мерзлоты и растительности [43]. Кроме того, совместное использование данных с TerraSAR-X и TanDEM-X в конфигурации, показанной на рис. 2.18, позволяет осуществлять высокоточную интерферометрическую обработку (заявленная точность порядка см), а также применяется в создании глобальной цифровой модели рельефа с точностью по относительной высоте до 2 м, материалы которой легли в основу проекта WorldDEM [44]. Глобальная цифровая модель рельефа WorldDEM является высокодетальным продуктом с полным охватом земной поверхности, пришедшая на смену продукту SRTM [45] в 2014 году. На рис. 2.21 приведены фрагменты цифровой модели рельефа SRTM и WorldDEM.




Рис. 2.21. Фрагменты цифровых моделей рельефа:
 а – SRTM (пространственное разрешение 90 м);
 б – WorldDEM (пространственное разрешение 12 м) [46]

Коммерческий успех аппаратов TerraSAR-X и TanDEM-X положил начало разработке миссии следующего поколения – TanDEM-L, состоящего из двух идентичных аппаратов, оснащенных РСА-датчиком L-диапазона (рабочая длина волны 23,6 см). Помимо дополнения данных своих предшественников, в задачи миссии TanDEM-L будет входить предсказание землетрясений за счет наблюдений подвижек рельефа с точностью порядка мм, мониторинг движения ледников и другие задачи, связанные с динамикой земного покрова. Запуск аппаратов предварительно запланирован на 2022 год.

2.9. PAZ

PAZ – испанский спутник дистанционного зондирования Земли, оборудованный РСА-датчиком X-диапазона (рабочая длина волны 3,1 см). Запуск состоялся в феврале 2018 года, высота солнечно-синхронной орбиты 508 км, наклонение $97,4^\circ$ [47]. Спутник PAZ является дополнением миссии космических аппаратов TerraSAR-X и TanDEM-X, позволяющим улучшить временное разрешение для задач мониторинга окружающей среды и предотвращения чрезвычайных ситуаций. Также космоснимки

PAZ применяются для пограничного контроля и разведки, планирования развития инфраструктуры и мониторинга стихийных бедствий.

Размер антенны РСА-датчика составляет $4,8 \times 0,7$ м. Поддерживается три основных режима работы: прожекторный SpotLight, маршрутный StripMap и сканирующий ScanSAR [48] (табл. 2.12). Прожекторный режим съемки подразделяется на два подрежима: собственно, SpotLight, позволяющий формировать РЛИ с пространственным разрешением до 1 м, и Staring SpotLight, обеспечивающий детальность изображений до 0,25 м. Маршрутный режим является режимом работы сенсора по умолчанию. Маршрутный и прожекторный режимы работы поддерживают как одиночный (HH, VV, HV либо VH), так и двойной (HH + HV, VV + VH либо HH + VV) тип поляризации. В сканирующем режиме работы также выделяют два подрежима: ScanSAR, обеспечивающий охват территории до 150 км в среднем пространственном разрешении, и режим сверхширокого обзора Wide Swathe ScanRadar с охватом местности до 270 км. В сканирующем режиме съемки поддерживается только одиночный тип поляризации (HH, VV, HV либо VH). Спутник обеспечивает формирование более чем 200 радиолокационных космоснимков за один день. На рис. 2.22 приведен фрагмент РЛИ, полученного с использованием аппаратуры спутника PAZ.

Таблица 2.12

Основные режимы работы РСА-датчика аппарата PAZ

Режим	Пространственное разрешение, м	Полоса обзора, км	Угол визирования, °
Staring SpotLight	0,25 ¹⁹	4	20–55
SpotLight	1	5	20–55
StripMap	3 ²⁰ /6 ²¹	30/15	20–45
ScanSAR	18,5	150	20–45
Wide Swathe	40	270	16–49

¹⁹ Только для военных миссий.

²⁰ В режиме одиночной поляризации.

²¹ В режиме двойной поляризации.




Рис. 2.22. Фрагмент космоснимка, полученного с космического аппарата PAZ (режим Spotlight, поляризация VV + HR), Сиэтл, штат Вашингтон, США, апрель 2018 год [47]

Логическим дополнением миссии аппарата PAZ становится спутник Ingenio (SEOSAT-Ingenio), выведенный на орбиту в сентябре 2020 года (высота орбиты 670 км, наклонение $98,0^\circ$) [49]. Полезная нагрузка спутника включает три инструмента: мультиспектральную камеру, обеспечивающую оптическую съемку земной поверхности в многозональном режиме (пространственное разрешение 10 м), панхроматическую камеру (пространственное разрешение 2,5 м) и датчик наблюдения за атмосферой в видимом и ультрафиолетовом диапазонах.

2.10. Основы распознавания пространственно-распределённых целей

Применение сверхширокополосных сигналов и эффекта синтеза апертуры за счёт движения Земли, перемещения космических, воздушных летательных аппаратов позволяет получить радиолокационное изображение (РЛИ) пространственно-распределённой цели (ПРЦ), характеризующееся достаточно высокой разрешающей способностью, при которой наблюдатель имеет возможность решать задачу классификации и распознавания названных ПРЦ.

Проблема классификации радиолокационных изображений ПРЦ, формируемых с помощью таких средств наблюдения, является частной задачей классической теории распознавания образов – ведущего научного направления современного естествознания, сложившегося и интенсивно развивающегося в течение последних десятилетий.

Фундаментальные основы статистической теории распознавания заложены в трудах Т. Андерсона [50], А.А. Харкевича [51], Г.С. Себастиана [52], М.М. Бонгарда [53] и др. Современное состояние этой теории подробно отражено в работах В.Н. Вапника и А.Я. Червоненкиса [54], Р. Дуды и П. Хафа [55], В.А. Ковалевского [56], Дж. Ту и Р. Гонсалеса [57], А.Л. Горелика [58,59] и других авторов [60, 61].

Пространственно-распределенная цель представляет собой совокупность центров стабильного отражения («блестящих точек») и большого числа статистически однородных отражателей, равномерно распределенных по поверхности цели. В качестве модели последних может быть принята абсолютно шероховатая поверхность, отражения от которой образуют так называемую диффузионную составляющую сигнала.

Количество, положение и ЭПР центров стабильного отражения остаются практически постоянными при изменении ракурса цели на несколько градусов.

Примерами пространственно-распределённых целей могут служить радиолокационные изображения надводных кораблей, полученных космической РЛС с синтезированной апертурой.

На рис. 2.23 представлены РЛИ надводных кораблей для различных условий наблюдения [62, 63] при разрешающей способности РСА – верхний ряд – 15 м и нижний ряд – 35 м; ракурсе наблюдения 283° (А – В), 315° (Г – Е) и 270° (Ж – И); отсутствии качки (А, Г, Ж) и наличии боковой качки 10° на сторону (Б и Д) и 15° на сторону (В и Е), а также при совместном воздействии килевой качки и рысканья $\pm 7^\circ$ (З, И), где R – это направление по дальности, X – направление по азимуту.

Формулировка существа проблемы заключается в том, чтобы, располагая исходным множеством объектов классификации и заданным априори принципом разделения этого множества на классы, распознающий

автомат (РА) в соответствии с оптимальным или близким к нему алгоритмом сформировал из наблюдаемых данных вектор признаков $L = \{l_1, \dots, l_k\}$ и в соответствии с эффективным решающим правилом разделил пространство признаков таким образом, чтобы, в лучшем случае, с максимальной, а в худшем случае, с заданной вероятностью определить класс очередного обнаруженного объекта. При этом общая постановка задачи классификации объектов радиолокационного наблюдения может быть сформулирована следующим образом.




Рис. 2.23. Примеры РЛИ ПРЦ (надводных кораблей)

Пусть задано множество B объектов различных типов. Система классификации состоит из P радиолокационных средств, содержащих РА. В каждом из таких РА используется множество радиолокационных сигналов S , на базе которых образуется множество признаков распознавания и множество правил принятия решения о классе наблюдаемого объекта K . Кроме того, введем множество параметров x , связанных с объектом и условиями его наблюдения, причем часть названных параметров x могут быть измерены РА, а часть параметров x_0 не измеряются в процессе решения задачи классификации, но существенным образом влияют на ее эффективность, которая оценивается с помощью некоторого критерия $\Theta\{\cdot\}$.

Если стоимость создания системы классификации C , а общие ассигнования – C_0 , то формально решение задачи сводится к отысканию экстремума функционала:

$$\exists \{P, S, L, K, x/B\} \quad (2.10.1)$$

при ограничении

$$C \leq C_0. \quad (2.10.2)$$

Точные методы решения этой задачи неизвестны, что, вообще говоря, достаточно естественно в связи с чрезвычайно общим характером ее постановки. Разумной альтернативой может служить переход к более частной конкретной задаче с учетом реальных условий, связанных с особенностями решаемой проблемы. При рассматриваемой в работе классификации ПРЦ следует учесть некоторые ограничения, а именно, выраженный статистический характер проблемы, связанный с природой наблюдаемых данных и практической невозможностью решения электродинамической задачи, определяет целесообразность использования вероятностных признаков, отказываясь от детерминированного, логического и структурного подходов [64].

Указанные ограничения определяют методологию подхода к решению задачи классификации ПРЦ. При использовании любого из известных статистических критериев вектор оптимальных признаков L должен быть образован на основе коэффициентов правдоподобия Δ_1, Δ_M (где M – число классов) – достаточных статистик, а разбиение пространства решения на области, соответствующие каждому из классов, производится гиперплоскостями (причем, коэффициентами в уравнениях таких плоскостей служат в общем случае элементы матрицы стоимостей).

При полной априорной определенности о распознаваемых классах и условиях наблюдения, а также отсутствии технических ограничений на этом проблема была бы исчерпана. Однако при практическом использовании РА оба названных требования далеки от реальности. В первую очередь это связано с наличием множества мешающих параметров χ ,

которое делится на два подмножества: x – подмножество принципиально не измеряемых параметров и x_0 – подмножество параметров, оцениваемых по наблюдаемым данным.

Если $U(t)$ – вектор-функция наблюдаемых данных, то эффективные признаки следует искать, отталкиваясь от коэффициентов правдоподобия:

$$L_{ij} = \frac{P\{U(t)/\overline{x_0}, \overline{x_i}, B_j\}}{P(\overline{U}(t)/B=0)}, \quad (2.10.3)$$

где $P\{\cdot\}$ – условный функционал плотности вероятности для реализации $U(t)$;

x_0 – вектор оценок измеряемых параметров;

x_i – i -я комбинация неизвестных параметров;

B_j – указание на наличие цели j -го класса (при $B = 0$ цель отсутствует).

Следует заметить, что размерность вектора L становится чрезвычайно большой в связи с континуальным в общем случае характером вектора x . С другой стороны, при его формировании возникает ряд проблем алгоритмического и технического характера. И, наконец, существующая в современных условиях база данных о радиолокационных портретах (РП) ПРЦ обычно настолько мала, что не позволяет говорить о достаточно достоверных сведениях о подавляющем большинстве индивидуальных характеристик, конструктивных и геометрических особенностей ПРЦ. Последнее обстоятельство не позволяет получить вектор с составляющими компонентами типа (2.10.3) и использовать их для классификации.

В связи с этим применяется следующая методология отыскания признаков. Названный вектор ищется на основе выражений для достаточных статистик в предположении о том, что РП и условия наблюдения заданы. После отыскания этих признаков они последовательно модифицируются с тем, чтобы полностью учесть имеющуюся априорную информацию с одновременным отказом от учета тех структурных и алгоритмических особенностей, которые недоступны на этапах проектирования и начальной боевой эксплуатации РА. В тоже время полученные алгоритмы не исключают, а напротив, предусматривают адаптацию к новым данным

о РП и условиям наблюдения, полученным при опытной и боевой эксплуатации систем МКРЦ. Аналогичный подход реализуется и по отношению к решающим правилам.

Ряд конкретных решений задачи классификации ПРЦ приведён в работах [65–70].

2.11. Литература к главе 2

1. Верба В.С., Неронский Л.Б., Осипов И.Г., Турук В.Э. Радиолокационные системы землеобзора космического базирования / под ред. В.С. Вербы. М.: Радиотехника, 2010. 680 с.

2. Официальный сайт японского космического агентства. Миссия ALOS. URL: <https://www.eorc.jaxa.jp/ALOS/en/index.htm> (дата обращения: 29.09.2020).

3. Официальный сайт аргентинского космического агентства. Миссия SAOCOM. URL: <https://www.argentina.gob.ar/ciencia/conae/satellite-saocom-contribucion-argentina-al-sistema-siasge> (дата обращения: 29.09.2020).

4. Дубошин Г.Н. Небесная механика. Основные методы и задачи. М.: Наука, 1968. 800 с.

5. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ALOS. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/a/alos> (дата обращения: 29.09.2020).

6. Lu Zh., Wicks Jr. Ch. Characterizing 6 August 2007 Crandall Canyon mine collapse from ALOS PALSAR InSAR // *Geomatics, Natural Hazards and Risk*. 2010. Vol. 1, № 1. P. 85–93.

7. Дагаев М.М. Наблюдения звёздного неба. 6-е изд., доп. М.: Наука, 1988. 176 с.

8. Официальный сайт компании «СКАНЭКС». URL: <http://www.scanex.ru/> (дата обращения: 29.09.2020).

9. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ALOS-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/a/alos-2> (дата обращения: 29.09.2020).

10. Официальный сайт японского космического агентства. Миссия ALOS-3. URL: <https://global.jaxa.jp/projects/sat/alos3/> (дата обращения: 29.09.2020).

11. ГОСТ 24375-80. Радиосвязь. Термины и определения. М.: Стандартинформ, 2005. 70 с.

12. Обзор систем землеобзора от европейского космического агентства (ESA). Группировка COSMO-SkyMed. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/cosmo-skymed> (дата обращения: 29.09.2020).

13. Большая советская энциклопедия (в 30 т.) / под ред. А.М. Прохорова. 3-е изд. М.: Советская энциклопедия, 1969–1978.
14. Описание миссии и продуктов COSMO-SkyMed (Электронное издание https://www.asi.it/wp-content/uploads/2019/08/COSMO-SkyMed-Mission-and-Products-Description_rev3-1.pdf). 2019, вып. 3. 151 с.
15. Официальный сайт европейского космического агентства. Космический аппарат ERS. URL: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/ers> (дата обращения: 29.09.2020).
16. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ERS-1. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/e/ers-1> (дата обращения: 29.09.2020).
17. Официальный сайт европейского космического агентства. Космический аппарат ERS-2. URL: <https://earth.esa.int/web/sppa/mission-performance/esa-missions/ers-2/> (дата обращения: 29.09.2020).
18. Horstmann J., Schiller H., Schulz-Stellenfleth J., Lehner S. Global wind speed retrieval from SAR // IEEE Transactions on geoscience and remote sensing. 2003. Vol. 41, № 10. P. 2277–2286.
19. Astronomical Table of the Sun, Moon and Planets, 3rd edition / ed. J. Meeus. Richmond: Willmann-Bell, 1995. 491 p.
20. Официальный сайт мирового центра по сбору данных дистанционного зондирования земной атмосферы. Описание платформы космического аппарата Envisat. URL: <http://wdc.dlr.de/sensors/sciamachy/envisat.php> (дата обращения: 29.09.2020).
21. Официальный сайт сервиса CLOBICE. URL: <http://www.globice.info/Section.php?pid=13> (дата обращения: 29.09.2020).
22. Обзор систем землеобзора от европейского космического агентства (ESA). Группировка спутников RCM. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/r/rcm> (дата обращения: 29.09.2020).
23. Официальный сайт канадского космического агентства. Миссия RADARSAT. URL: <https://www.asc-csa.gc.ca/eng/satellites/radarsat/default.asp> (дата обращения: 29.09.2020).
24. Официальный сайт европейского космического агентства. Космический аппарат RADARSAT-1. URL: <https://earth.esa.int/web/eoportal/satellite-missions/r/radarsat-1> (дата обращения: 29.09.2020).
25. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник RADARSAT-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/r/radarsat-2> (дата обращения: 29.09.2020).

26. Описание продуктов RADARSAT-2 (Электронное издание https://mdacorporation.com/docs/default-source/technical-documents/geospatial-services/52-1238_rs2_product_description.pdf). 2018, вып.1/14. 91 с.

27. Официальный сайт европейского космического агентства. Группировка RCM. URL: <https://earth.esa.int/web/eoportal/satellite-missions/r/rcm> (дата обращения: 29.09.2020).

28. Manore M., DeAbreu R., Zabeline V., Arkett M., Bradley D. The RADARSAT Constellation Mission (RCM): extending operational marine surveillance for environment Canada // Proceedings of ASTRO 2010, 15th CASI (Canadian Aeronautics and Space Institute) Conference. 2010. P. 136–141.

29. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-1. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1> (дата обращения: 29.09.2020).

30. Sentinel-1 data available on AWS and through Sentinel Hub (электронный ресурс <https://medium.com/sentinel-hub/sentinel-1-data-available-on-aws-and-through-sentinel-hub-ecc51c910db6>) (дата обращения: 29.09.2020).

31. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник Sentinel-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-2> (дата обращения: 29.09.2020).

32. Официальный сайт миссии Copernicus. Спутник Sentinel-2. URL: <https://www.copernicus.eu/en/media/images/sentinel-2-1> (дата обращения: 29.09.2020).

33. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-3. URL: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-3> (дата обращения: 29.09.2020).

34. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник Sentinel-5P. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-5p> (дата обращения: 29.09.2020).

35. Официальный сайт Европейской организации спутниковой метеорологии (EUMETSAT). Цели миссии Sentinel-4. URL: <https://www.eumetsat.int/website/home/Satellites/FutureSatellites/CopernicusSatellites/Sentinel4/index.html> (дата обращения: 29.09.2020).

36. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-5. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-5> (дата обращения: 29.09.2020).

37. Официальный сайт миссии Copernicus. URL: <https://www.copernicus.eu/en> (дата обращения: 29.09.2020).

38. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник TerraSAR-X. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/t/terrasar-x> (дата обращения: 29.09.2020).

39. Описание продуктов TerraSAR-X (Электронное издание https://www.intelligence-airbusds.com/files/pmedia/public/r459_9_20171004_tsxx-airbusds-ma-0009_tsx-productguide_i2.01.pdf). 2015, вып.2.1. — 24 с.

40. Официальный сайт сервиса GEOCENTO. Коллекция космоснимков спутника TerraSAR-X. URL: <https://geocento.com/satellite-imagery-gallery/terrasar-x/> (дата обращения: 29.09.2020).

41. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник TanDEM-X. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/t/tandem-x> (дата обращения: 29.09.2020).

42. Официальный сайт европейского космического агентства. Спутник TanDEM-X. URL: <https://earth.esa.int/web/eoportal/satellite-missions/t/tandem-x> (дата обращения: 29.09.2020).

43. Официальный сайт компании Airbus. Описание продуктов WorldDEM. URL: <https://www.intelligence-airbusds.com/en/8703-worlddem> (дата обращения: 29.09.2020).

44. Официальный сайт продукта SRTM URL: <http://srtm.csi.cgiar.org/> (дата обращения: 29.09.2020).

45. GIS resources. WorldDEM. URL: <http://www.gisresources.com/reach-accurate-heights-worldtm-dataset/> (дата обращения: 29.09.2020).

46. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник PAZ. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/p/paz> (дата обращения: 29.09.2020).

47. Официальный сайт европейского космического агентства. Спутник PAZ. URL: <https://earth.esa.int/web/eoportal/satellite-missions/p/paz> (дата обращения: 29.09.2020).

48. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник SEOSAT-Ingenio. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/s/seosat> (дата обращения: 29.09.2020).

49. Баскаков А.И., Лукашенко Ю.И., Щернакова Л.А. Зондирующие радиолокационные сигналы: Учебное пособие / под ред. А.Ф. Богомолова. М.: Издательство МЭИ, 1990. 79 с.

50. Андерсон Т. Введение в многомерный статистический анализ / Т. Андерсон; пер. с англ. Б.В. Гнеденко. М. Физматгиз, 1963. 500 с.
51. Харкевич А.А. Избранные труды. В 3 т. Т. 3. Теория информации. Опознавание образов / А.А. Харкевич. М.: Наука, 1973. 524 с.
52. Себастиан Г.С. Процессы принятия решений при распознавании образов / Г.С. Себастиан; пер. с англ. Ивахненко. Киев: Техника, 1965. 152 с.
53. Бонгард М.М. Проблема узнавания / М.М. Бонгард. М.: Наука, 1967. 320 с.
54. Вапник В.Н. Теория распознавания образов (статистические проблемы обучения) / В.Н. Вапник, А.Я. Червоненкис. М.: Наука, 1974. 616 с.
55. Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт; пер с англ. В.Л. Стефанюка. М.: Мир, 1976. 511 с.
56. Ковалевский В.А. Методы оптимальных решений в распознавании изображений / В.А. Ковалевский. М.: Наука, 1976. 328 с.
57. Ту Дж. Принципы распознавания образов / Дж. Ту, Р. Гонсалес; пер. с англ. М. Журавлева. М.: Мир, 1978. 412 с.
58. Селекция и распознавание на основе локационной информации / под ред. А.Л. Горелик. М. Радио и связь. 1990. 236с.
59. Горелик А.Л. Методы распознавания / А.Л. Горелик, В.А. Скрипкин. М.: Высшая школа 1984. 208 с.
60. Достовалов М.Ю., Лифанов А.С., Мусинянц Т.Г. Система автоматизированного распознавания объектов на основе исследования радиолокационных портретов по изображениям PCA КОМПАКТ-100. Исследования Земли из космоса, № 1, 2005.
61. Diemunsch J., Wissinger J. MSTAR model-based automatic target recognition: search technology for a robust ATR. Algorithms for Synthetic Aperture Radar Imagery V, E. Zein, Eds. // Proceedings of SPIE, Vol. 3370, 1998.
- Каталог изображений Земли. Продукция космического аппарата «Алмаз-1». ОАО «НПО машиностроения». Вэб-сайт <http://almaz1.ru>.
63. Дикинис А.В., Иванов А.Ю., Карлин Л.Н., Неронский Л.Б. и др. Атлас аннотированных радиолокационных изображений морской поверхности, полученных космическим аппаратом «Алмаз – 1». М.: ГЕОС, 1999.
64. Благовещенский С.Н. Справочник по динамике и статике корабля в 2 т. / С.Н. Благовещенский, А.Н. Холодилин. Л.: Судостроение, 1975. т. 2. 176 с.

65. Доросинский Л.Г. Классификация пространственно-распределенных объектов по данным РЛС бокового обзора / Л.Г. Доросинский, Т.М. Лысенко // Радиотехника 3. 1996. С. 8-12.

66. Доросинский Л.Г. Исследование алгоритмов распознавания радиолокационных изображений распределённых объектов. 23-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 8–18 сентября 2013.

67. Доросинский Л.Г. Синтез и анализ алгоритмов классификации радиолокационных сигналов 23-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 8-18 сентября 2013.

68. Доросинский Л.Г. Синтез алгоритма распознавания классов радиолокационных сигналов. 24-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 7–13 сентября 2014.

69. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография. М.: Издательский дом Академии Естествознания, 2017. 212 с.

70. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018.-264 с.

3. КЛАССИФИКАЦИЯ ПРЦ ПО ДАННЫМ КОСМИЧЕСКОЙ РЛС БОКОВОГО ОБЗОРА С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ

3.1. Математическая модель цели и отражённого сигнала при решении задач распознавания пространственно- распределённых целей в космических РЛС с синтезированной апертурой

Синтез оптимального алгоритма классификации пространственно-распределённых целей (ПРЦ) по данным космического мониторинга земной и/или водной поверхности традиционно начинается с задания математической модели собственно цели и отражённого от неё сигнала. Процесс оптимальной обработки естественным образом содержит в качестве первичного алгоритма процедуру формирования, так называемого, радиолокационного изображений (РЛИ). Названное РЛИ вычисляется в результате сжатия широкополосного импульсного сигнала, обеспечивающего достаточно высокое разрешение по дальности и соответствующее сжатие азимутального сигнала путём когерентного накопления отражённых сигналов вдоль траектории полёта ЛА, реализующего синтез искусственного раскрыва антенны [1].

Основой синтеза является вычисление вектора достаточных статистик – суть отношений правдоподобия относительно ПРЦ каждого из возможных классов. Получение достаточной статистики в первую очередь требует записи математической модели как собственно ПРЦ, так и отражённого от неё сигнала.

Относительное размещение ПРЦ и носителей РСА показано на рис. 3.1, где введены две системы координат: основная неподвижная $OXYZ$ и вспомогательная $oxyz$, связанная с геометрическими осями цели.

Отражающие свойства наблюдаемых ПРЦ описаны комплексной функцией отражения $f_k^p(\bar{x})$ k -й ПРЦ при наблюдении его p -ой РЛС. В общем случае считаем, что число РЛС совпадает с числом малых спутников, входящих в группировку, и равно P . Радиус-вектор элементарного отражающего участка (точки) во вспомогательной системе координат обозначим, как $\bar{x}$.

Как показано в [1], функция отражения имеет две независимые составляющие – диффузионную $f_k^p(\bar{x})$, связанную с рассеянными отражениями от поверхности цели, и «зеркальную» $f_{k\sigma}^p(\bar{x})$, появление которой вызвано наличием зеркально отражающих элементов конструкции и элементов типа уголкового отражателей. Эта компонента представляет собой математическую модель физической совокупности центров стабильного отражения, условно именуемых «блестящими точками», в то время как первая составляющая представляет собой непрерывную функцию координат. Из высказанных соображений следует традиционное представление функции отражения в виде следующей формулы:

$$\dot{f}_k^p(\bar{x}) = f_{k0}^p(\bar{x}) + f_{k\sigma}^p(\bar{x}) \Leftrightarrow = f_{k0}^p(\bar{x}) + \sum_{i=1}^{N_{kp}} f_{ki}^p \delta(\bar{x} - \bar{x}_{ki}^p), \quad (3.1.1),$$

где f_{ki}^p – значение комплексной функции отражения для i -й «блестящей точки» k -й цели при наблюдении ее p -й РЛС;

N_{kp} – общее число «блестящих точек» при наблюдении цели k -го класса p -й РЛС;

$\delta(\bar{x})$ – дельта-функция;

$\bar{x}_{ki}$ – радиус-вектор i -й «блестящей точки».

В общем случае следует иметь в виду, что вид функции отражения $f_k^p(\bar{x})$ существенным образом зависит от ракурса наблюдения цели, что не отмечено в (3.1.1) для сокращения записи.

При использовании Р РЛС, входящих в группировку малых спутников, объединим функции отражения в p -компонентный вектор

$$\bar{f}_k(\bar{x}) = \bar{f}_{k0}(\bar{x}) + \bar{f}_{k\sigma}(\bar{x}), \quad (3.1.2),$$

где диффузионная составляющая описывается p -мерным гауссовским функционалом плотности распределения вероятностей с нулевым вектором средних значений.

Функции отражения соседних элементарных участков поверхности считаем статистически независимыми. При этом матрица взаимных корреляционных функций компонент вектора $\bar{f}_{k0}(\bar{x})$ может быть представлена в следующем виде:

$$\langle 0,5 \bar{f}_{k0}(\bar{x}) \times \bar{f}_{k0}(\bar{y}) \rangle = \sum_{k0} (\bar{x}) \delta(\bar{x} - \bar{y}). \quad (3.1.3)$$

Матрица $\sum_{k0}(\bar{x})$ в общем случае является эрмитовой, положительно определенной.




Рис. 3.1. Геометрические соотношения для p -й РЛС системы

При независимых сигналах РЛС каждого спутника матрица вырождается в вещественную диагональную. Когда сигналы всех РЛС, входящих в группировку, абсолютно когерентны матрица $\sum_{k0}(\bar{x})$ вырождается

в вещественную с равными элементами, что дает возможность представить ее в виде²²

$$\sum_{k0}(\bar{x}) = \sigma_{k0}^2(\bar{x}) \bar{e}_0 \bar{e}_0^T, \quad (3.1.4)$$

где $\sigma_{k0}^2(\bar{x})$ – распределение дисперсии диффузионной составляющей функции отражения по поверхности цели k -го класса;
 $\bar{e}_0$ – p -компонентный вектор-столбец, все элементы которого равны единице.

Для описания статистических свойств отраженных сигналов в литературе, как правило, используются три модели [2]:

- детерминированные отражения;
- для каждой «блестящей точки» амплитуда детерминирована, в то время как фаза случайна и равномерно распределена на интервале $[-\pi, \pi]$;
- для каждой «блестящей точки» отраженный сигнал случаен и подчинен нормальному распределению плотности вероятности с нулевым математическим ожиданием.

При характерном для космических РСА времени наблюдения (менее 1 секунды) диффузионную составляющую можно считать квазидетерминированной, то есть случайной, но не изменяющейся за время наблюдения. Аналогичное предположение может быть высказано относительно функций отражения для «блестящих точек». При этом основным отличием «блестящих точек» от диффузионной составляющей функции отражения является их дискретный характер. Кроме того, суммарная ЭПР «блестящих точек» обычно предполагается много большей ЭПР поверхности цели и составляет до 80 % всей ЭПР цели [3]. Далее предполагаем, что функция отражения нормирована к суммарной ЭПР k -й цели таким образом, что выполняется равенство:

$$\iint \langle 0,5 \rangle f_K^p(\bar{x}) f_K^{p*}(\bar{y}) d\bar{x} d\bar{y} = 1. \quad (3.1.5)$$

Считая радиолокационные станции для каждого элемента системы наблюдения бистатистическими (передающая РЛС и принимающая РЛС

²² Такая ситуация принципиально возможна, если спутники настолько близки друг к другу, что отраженные сигналы практически не отличаются друг от друга в разных РЛС.

образуют пару, расположенную на двух спутниках), запишем принимаемый сигнал в виде p -компонентного вектора комплексных амплитуд:

$$\begin{aligned} \bar{U}(t) = U_{kh} \int_{\Omega_k} \dot{f}_k^p(\bar{x}) \frac{g_{1p}(\bar{x}, t) g_{2p}(\bar{x}, t)}{r_{1p}(\bar{x}, t) r_{2p}(\bar{x}, t)} \dot{s}_p \left\{ t - \frac{r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)}{c} \right\} \times \\ \times \exp \left\{ -jk_p [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)] \right\} d\bar{x} + N_p(t), \end{aligned} \quad (3.1.6)$$

где $g_{1p}(\bar{x}, t)$, $g_{2p}(\bar{x}, t)$ – значения нормированных диаграмм направленности передающей и приемной антенн p -й РЛС в направлении точки цели $\bar{x}$ в момент времени t ;

$r_{1p}(\bar{x}, t)$, $r_{2p}(\bar{x}, t)$ – текущее значение дальности от передатчика и приемника p -й РЛС до точки $\bar{x}$ цели;

$s_p(t)$ – комплексная амплитуда модулирующей функции зондирующего сигнала p -й РЛС, которую в дальнейшем считаем импульсной с длительностью импульса τ_p и периодом повторения T_p и нормированной таким образом, что выполняется условие:

$$\frac{1}{\tau_p} \int |s_p(t)|^2 dt = 1, \quad (3.1.7)$$

где $N_p(t)$ – комплексная амплитуда аддитивного шума радиолокационного тракта для p -й РЛС;

$k_p = 2\pi/\lambda$ – волновое число.

Время наблюдения цели каждой РЛС системы ограничено и равно T_{op} .

С учетом нормировок (3.1.5) и (3.1.7) вещественный множитель $U_{кр}$ имеет вид [4]:

$$U_{kp} = \sqrt{\frac{2P_{po}\lambda_p^2 G_{1p} G_{2p}}{(4\pi)^2} (\sigma_{ke}^p)^1}, \quad (3.1.8)$$

где P_{po} – импульсная мощность зондирующего сигнала p -й РЛС;

G_{1p} , G_{2p} – коэффициенты направленного действия (КНД) передающей и приемной антенн p -й РЛС;

σ_{ke}^p – суммарная ЭПР k -й цели при приеме сигнала p -й РЛС.

Введем диагональные матрицы размерности $p \times p$:

$$G(\bar{x}, t) = \text{diag}[G_1(\bar{x}, t), G_2(\bar{x}, t), \dots, G_p(\bar{x}, t)];$$

$$S(\bar{x}, t) = \text{diag}[S_1(\bar{x}, t), S_2(\bar{x}, t), \dots, S_p(\bar{x}, t)];$$

$$E(\bar{x}, t) = \text{diag}[E_1(\bar{x}, t), E_2(\bar{x}, t), \dots, E_p(\bar{x}, t)];$$

$$U_k = \text{diag}[U_{k1}, U_{k2}, \dots, U_{kp}]; \quad (3.1.9)$$

$$G_p(\bar{x}, t) = \frac{g_{1p}(\bar{x}, t)g_{1p}(\bar{x}, t)}{r_{1p}(\bar{x}, t)r_{1p}(\bar{x}, t)}; \quad (3.1.10)$$

$$S_p(\bar{x}, t) = s_p \left\{ t - \frac{r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)}{c} \right\}; \quad (3.1.11)$$

$$E_p(\bar{x}, t) = \exp \left\{ -\frac{jk_p [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)]}{c} \right\}. \quad (3.1.12)$$

Используя (2.1.2), вектор комплексных амплитуд представим в виде суммы:

$$\bar{U}(t) = \bar{U}_{k0}(t) + \bar{U}_{k\sigma}(t) + \bar{N}(t), \quad (3.1.13)$$

где
$$\bar{U}_{k0}(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k0}(\bar{x}) d\bar{x}; \quad (3.1.14)$$

$$\bar{U}_{k\sigma}(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k\sigma}(\bar{x}) d\bar{x}; \quad (3.1.15)$$

$$N(t) = \{N_1(t), N_2(t), \dots, N_p(t)\}. \quad (3.1.16)$$

Компоненты шума (3.1.16) будем считать гауссовскими белыми и статистически независимыми между собой. Вектор $N(t)$ учитывает, как шумы приемников радиолокационных станций, так и сигналы, отраженные статистически однородной подстилающей поверхностью.

Из (3.1.6) следует, что для полного описания принимаемых сигналов необходимо в явном виде знать зависимость дальностей r_1 и r_2 от координат отражающей точки и текущего времени.

На рис. 3.1 движения носителей передающей (Прд.р) и приемной (Прм.р) частей p -й РЛС описываются в основной системе координат $OXYZ$ радиус-векторами $\vec{r}_1^p(t)$ и $\vec{r}_2^p(t)$. Движение центра масс наблюдаемой цели характеризуется радиус-вектором $r(t)$. Для описания движения произвольной точки $\vec{x}$ цели относительно центра масс в основной системе координат используем вектор $\vec{\rho}_p(\vec{x}, t)$. В произвольный момент времени t связь векторов $\vec{\rho}_p(\vec{x}, t)$ и $\vec{x}$ задается выражением [1]:

$$\vec{\rho}_p(\vec{x}, t) = A_p(t_i) \vec{x}, \quad (3.1.17)$$

где $A_p(t_i)$ – матрица поворота осей вспомогательной системы координат относительно основной системы $OXYZ$ в момент t_i .

Без учета смещения носителей приемной и передающей частей РЛС за время распространения сигнала до цели и обратно искомые зависимости описываются выражениями:

$$\vec{r}_{1p}(\vec{x}, t) = \left| \vec{r}_{0p}(t) + \vec{\rho}_p(\vec{x}, t) - \vec{r}_1^p(t) \right|; \quad (3.1.18)$$

$$\vec{r}_{2p}(\vec{x}, t) = \left| \vec{r}_{0p}(t) + \vec{\rho}_p(\vec{x}, t) - \vec{r}_2^p(t) \right|. \quad (3.1.19)$$

Поскольку формулы (3.1.18) и (3.1.19) отличаются только индексами, то дальнейшие выкладки выполнены лишь для первой из них.

Разложим (3.1.18) в ряд Тейлора в окрестности точки t_{0p} , соответствующей середине интервала наблюдения цели p -й РЛС

$$r_{1p}(\vec{x}, t) = r_{1p}(\vec{x}, t_{0p}) + \sum_{i=1}^{\infty} \frac{1}{i!} \vec{r}_{1p}^{(i)}(\vec{x}, t_{0p}) \cdot (t - t_{0p})^i, \quad (3.1.20)$$

где $r_{1p}^{(i)}(\vec{x}, t_{0p})$ – значение i -й производной функции $r_{1p}(\vec{x}, t)$ по времени в момент $t = t_{0p}$.

Используя правила дифференцирования векторов и их модулей, получим выражения для первых четырех производных:

$$r_{1p}^{(1)}(\vec{x}, t_{0p}) = \vec{e}_{1p}^{(1)}(\vec{x}, t_{0p}) \cdot \vec{v}_{1p}^{(1)}(\vec{x}, t_{0p}); \quad (3.1.21)$$

$$r_{1p}^{(2)}(\bar{x}, t_{0p}) = \frac{|\bar{v}_{1p}(\bar{x}, t_{0p})|^2 - |r_{1p}^{(1)}(\bar{x}, t_{0p})|^2}{|r_{1p}(\bar{x}, t_{0p})|} \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{A}_{1p}(\bar{x}, t_{0p}); \quad (3.1.22)$$

$$r_{1p}^{(3)}(\bar{x}, t_{0p}) = 3 \frac{\bar{v}_{1p}(\bar{x}, t_{0p}) \cdot \bar{A}_{1p}(\bar{x}, t_{0p}) - r_{1p}^{(1)}(\bar{x}, t_{0p}) r_{1p}^{(2)}(\bar{x}, t_{0p})}{|r_{1p}(\bar{x}, t_{0p})|} \times \\ \times \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{W}_{1p}(\bar{x}, t_{0p}); \quad (3.1.23)$$

$$r_{1p}^{(3)}(\bar{x}, t_{0p}) = 3 \frac{|\bar{A}_{1p}(\bar{x}, t_{0p})|^2 - |r_{1p}^{(2)}(\bar{x}, t_{0p})|^2}{|r_{1p}(\bar{x}, t_{0p})|} + \\ + 4 \frac{\bar{v}_{1p}(\bar{x}, t_{0p}) \cdot \bar{W}_{1p}(\bar{x}, t_{0p}) - r_{1p}^{(1)}(\bar{x}, t_{0p}) \cdot r_{1p}^{(3)}(\bar{x}, t_{0p})}{|r_{1p}(\bar{x}, t_{0p})|} + \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{B}_{1p}(\bar{x}, t_{0p}); \quad (3.1.24)$$

$$\bar{e}_{1p}(\bar{x}, t_{0p}) = \frac{r_{0p}(t_{0p}) + \rho_p(\bar{x}, t_{0p}) - r_1^p(t_{0p})}{|r_{0p}(t_{0p}) + \rho_p(\bar{x}, t_{0p}) - r_1^p(t_{0p})|} \quad (3.1.25)$$

– единичный вектор визирования точки $\bar{x}$ в момент времени t ,

$$\bar{V}_{1p}(x, t) = \frac{d}{dt} [\bar{r}_{0p}(t) + \bar{\rho}_p(\bar{x}, t) - r_1^p(t)]; \quad (3.1.26)$$

$$\bar{A}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{V}_{1p}(x, t)]; \quad (3.1.27)$$

$$\bar{W}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{A}_{1p}(x, t)]; \quad (3.1.28)$$

$$\bar{B}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{W}_{1p}(x, t)]. \quad (3.1.29)$$

Полученные соотношения достаточно компактны и при наличии данных о параметрах траекторий движения носителей РЛС и цели могут быть использованы для решения задач синтеза и анализа алгоритмов обнаружения, измерения параметров и классификации ПРЦ.

3.2. Многоальтернативная проверка гипотез относительно различных классов ПРЦ при их наблюдении совокупностью космических радиолокационных средств

Определим класс наблюдаемой ПРЦ методом максимального правдоподобия. Для этого запишем условную плотность вероятности наблюдать вектор $\bar{U}(t)$ при наличии ПРЦ k -го класса. Общее число возможных классов считаем равным M , Гипотеза с номером $(M + 1)$ соответствует наблюдению только фона (ПРЦ отсутствует).

При точно известных параметрах, характеризующих условия наблюдения, оптимальная обработка сводится к вычислению отношений правдоподобия для всех M гипотез

$$l_k [\bar{U}(t)] = \ln \{L_k [\bar{U}(t)]\}$$

и выбора того номера k , при котором $l_k [\bar{U}(t)]$ максимально.

Достаточная статистика для принятия решения представляет собой вектор, составленный из отношений правдоподобия для каждой из M конкурирующих гипотез. Логарифм отношения правдоподобия для k -й гипотезы при отсутствии флуктуаций сигналов, отраженных «блестящими точками», может быть записан в виде [6]:

$$l_k [\bar{U}(t)] = \left\{ 0,5 \iint \bar{U}^*(t) Q_0(t, u) \bar{U}(u) dt du - \iint [\bar{U}^*(t) - \bar{U}_{k\sigma}^*(t)] Q_k(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] dt du - \ln(K_0/K_k) \right\}, \quad (3.2.1)$$

где K_0 и K_k – нормирующие коэффициенты функционалов плотности распределения вероятностей для случаев наблюдения только шума и k -й цели на фоне шума;

$Q_0(t, u)$, $Q_k(t, u)$ – комплексные матрицы, обратные матрицам взаимной корреляции принимаемого вектора $\bar{U}(t)$ для гипотез о наблюдении только шума $R(t, u)$ и k -й цели на фоне шума $R_k(t, u)$.

Поскольку шум и диффузионная составляющая принимаемого сигнала $\bar{U}_{k0}(t)$ являются независимыми случайными процессами, то

$$R_k(t, u) = R_{k0}(t, u) + R_0(t, u), \quad (3.2.2)$$

$$\text{где} \quad R_{k0}(t, u) = \langle 0, 5 \bar{U}_{k\sigma}(t) \times \bar{U}_{k\sigma}^*(u) \rangle \quad (3.2.3)$$

– матрица корреляционных функций диффузионных составляющих вектора принимаемого сигнала.

Для определения вида матриц $Q_0(t, u)$ и $Q_k(t, u)$ следует воспользоваться интегрально-матричными уравнениями обращения:

$$\int R_0(t, u) Q_0(u, v) du = I \delta(t - v); \quad (3.2.4)$$

$$\int R_k(t, u) Q_k(u, v) du = I \delta(t - v), \quad (3.2.5)$$

где I – единичная диагональная матрица.

Для последнего слагаемого в (3.2.1) справедливо равенство:

$$\ln(K_0/K_k) = Sp \int_0^1 \frac{dA}{A} \iint R_0(t, u) Q_{Ak}(u, t) dt du, \quad (3.2.6)$$

где $Q_{Ak}(u, t)$ – решение интегрально-матричного уравнения:

$$\iint [R_0(t_1, u) + AR_{k0}(t_1, u)] Q_{Ak}(u, v) R_0(v, t_2) dv = AR_{k0}(t_1, t_2). \quad (3.2.7)$$

При условии, что шум радиолокационного тракта «белый» с диагональной матрицей спектральных плотностей N_0 выражения (3.2.4–3.2.7) упрощаются:

$$Q_0(t, u) = N_0^{-1} \delta(t, u); \quad (3.2.8)$$

$$\int R_{k0}(t, u) Q_k(u, v) du + N_0 Q_k(t, v) = I \delta(t - v); \quad (3.2.9)$$

$$\ln(K_0/K_k) = Sp \int \frac{dA}{A} \int N_0 Q_{Ak}(t, t) dt; \quad (3.2.10)$$

$$N_0 Q_{Ak}(t, v) N_0 + A \int R_{k0}(t, u) Q_{Ak}(u, v) N_0 du = AR_{k0}(t, v). \quad (3.2.11)$$

Пользуясь рекомендациями [6], ищем матрицу $Q_k(t, u)$ в виде

$$Q_k(t, u) = N_0^{-1} [I\delta(t-u) - Q_{k0}(t, u)]. \quad (3.2.12)$$

В этом случае равенство (2.9) преобразуется следующим образом:

$$\int R_{k0}(t, u) N_0^{-1} Q_{k0}(u, v) du + Q_{k0}(t, v) = R_{k0}(t, v) N_0^{-1}. \quad (3.2.13)$$

Сравнение (2.2.11) с (2.2.13) показывает, что матрица $Q_{k0}(t, u)$ может быть найдена путем решения (2.2.11) при $A = 1$, т. е.

$$Q_{k0}(t, u) = N_0 Q_{Ak}(t, u)|_{A=1}. \quad (3.2.14)$$

Подставляя (2.2.8) в (2.2.1), получим:

$$I_k[\bar{U}(t)] = 0,5 \left\{ \iint [\bar{U}^*(t) - \bar{U}_{k\sigma}^*(t)] N_0^{-1} Q_{k0}(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] dt du - \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}_{k\sigma}(t) dt + 2Re \left[\int \bar{U}_{k\sigma}^*(t) \bar{U}_{k\sigma}(t) N_0^{-1} \bar{U}(t) dt \right] - \ln(K_0/K_k) \right\}. \quad (3.2.15)$$

Из (3.2.15) и рис. 3.2 следует, что алгоритм формирования отношения правдоподобия $l_k[\bar{U}(t)]$ содержит два канала. В первом из них вычисляется корреляция принимаемой реализации вектора $\bar{U}(t)$, нормированного к мощности шумов, с вектором ожидаемого сигнала, порожденного «блестящими точками» k -й цели $\bar{U}_{k\sigma}(t)$. Во втором канале разностный сигнал $\bar{U}(t) - \bar{U}_{k\sigma}(t)$ коррелируется с вектором

$$\int Q_{k0}(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] du,$$

который представляет собой оценку диффузионной составляющей принимаемого сигнала в предположении о наблюдении k -й цели.

Дальнейшая конкретизация алгоритма формирования логарифма отношения правдоподобия и структуры реализующего его устройства возможна лишь при определении матриц $Q_{Ak}(t, u)$ и $Q_{k0}(t, u)$, для чего необходимо решить уравнение (3.2.11). Прежде всего выясним вид корреляционной функции $R_{k0}(t, u)$. Используя (3.2.14) и (3.2.3), получим:

$$\begin{aligned} R_{k0}(t, u) &= \langle 0,5 \bar{U}_{k\sigma}(t) + \bar{U}_{k\sigma}^*(u) \rangle = \\ &= \int_{\Omega_k} U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) \sum_{k0} (\bar{x}) E^*(\bar{x}, t) S^*(\bar{x}, t) G(\bar{x}, t) U_k d\bar{x}. \end{aligned} \quad (3.2.16)$$

Воспользовавшись широко известным приемом [7], будем искать $Q_{Ak}(t, u)$ в виде, аналогичном (3.2.16):

$$Q_{Ak}(t, u) = \iint_{\Omega_k} N_0^{-1} U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) H_{Ak}(\bar{x}, \bar{y}) \times \\ \times E^*(\bar{y}, u) S^*(\bar{y}, u) G^*(\bar{y}, u) U_k N_0^{-1} d\bar{x} d\bar{y}. \quad (3.2.17)$$

После подстановки (3.2.16, 3.2.17) уравнение (3.2.11) может быть представлено в виде

$$H_{Ak}(\bar{x}, \bar{y}) + A \sum_{k0} (\bar{x}) U_k N_0^{-1} U_k \int \Psi^0(\bar{x}, \bar{z}) H_{Ak}(\bar{x}, \bar{z}) d\bar{z} = \\ = A \sum_{k0} (\bar{x}) \delta(\bar{x} - \bar{y}). \quad (3.2.18)$$

где введена матрица $(p \times p)$

$$\Psi^0(\bar{x}, z) = \int E^*(\bar{x}, u) S^*(\bar{x}, u) G^*(\bar{x}, u) G(\bar{z}, u) S(\bar{z}, u) E(\bar{z}, u) du. \quad (3.2.19)$$




Рис. 3.2. Вариант структурной схемы устройства формирования логарифма отношения правдоподобия

Подстановка (2.2.17) в (2.2.15) дает следующий результат:

$$I_k[\bar{U}(t)] = 0,5 \left\{ \iint_{\Omega_k} [\bar{F}^*(\bar{x}) - \bar{F}_{k\sigma}^*(\bar{x})] N_0^{-1} U_k H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} \times \right. \\ \times [\bar{F}^*(\bar{y}) - \bar{F}_{k\sigma}^*(\bar{y})] d\bar{x} d\bar{y} + 2 \operatorname{Re} \left[\int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}(t) dt \right] - \\ \left. - \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}_{k\sigma}(t) dt - \ln(K_0/K_k) \right\}; \quad (3.2.20)$$

$$H_{k0}(\bar{x}, \bar{y}) = H_{Ak}(\bar{x}, \bar{y})_{A=1}; \quad (3.2.21)$$

$$ESG(\bar{x}, u) = E(\bar{x}, u)S(\bar{x}, u)G(\bar{x}, u). \quad (3.2.22)$$

Используя (3.2.15), преобразуем второе и третье слагаемые в фигурных скобках (3.2.20). В результате получим:

$$\begin{aligned} I_k[\bar{U}(t)] = 0,5 \left\{ \iint_{\Omega_k} [\bar{F}^*(x) - \bar{F}_{k\sigma}^*(x)] N_0^{-1} U_k H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} \times \right. \\ \left. \times [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{x} d\bar{y} + 2Re \left[\int \bar{f}_{k\sigma}^*(\bar{x}) U_k N_0^{-1} \bar{F}(\bar{x}) d\bar{x} \right] \right\}. \end{aligned} \quad (3.2.23)$$

Кратко рассмотрим смысл введенных функций

$$\Psi^0(\bar{x}, \bar{z}), \quad \bar{F}(\bar{x}) \quad \text{и} \quad \bar{F}_{k\sigma}(\bar{x}).$$

Рассмотрим p -ю компоненту вектора $\bar{F}(\bar{x})$. При отсутствии шума с учетом (3.2.6) имеем:

$$\bar{F}_p(x) = U_{kp} \int_{\Omega_k} \Psi_p^0(\bar{x}, \bar{z}) f_k^p(\bar{z}) d\bar{z}. \quad (3.2.24)$$

Оптимальный алгоритм обработки представлен на рис. 3.3. Для выяснения физического смысла интеграла

$$\int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y}$$

умножим его слева на

$$U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t)$$

и проинтегрируем результат по $\bar{x}$. Учитывая (3.2.14) и (3.2.17), получим:

$$\begin{aligned} U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) \int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y} = \\ = \int Q_{k0}(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] du. \end{aligned} \quad (3.2.25)$$

Как уже отмечалось, правая часть (3.2.25) представляет собой оценку диффузионной составляющей принимаемого сигнала

в предположении о наблюдении k -й цели. Используя (3.2.14), представим эту оценку в виде:

$$U_{k0}^{\varepsilon}(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k\sigma}^{\varepsilon}(\bar{x}) d\bar{x} \quad (3.2.26)$$

составляющей функции отражения k -й цели по координатам. Сравнение (3.2.25) и (3.2.26) приводит к следующему результату:

$$\int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y} = f_{k\sigma}^{\varepsilon}(\bar{x}). \quad (3.2.27)$$

Полученный интеграл представляет собой оптимальную оценку диффузионной составляющей функции отражения ПРЦ в предположении о том, что справедлива k -я гипотеза.

Из выполненного синтеза следует, что необходимая для принятия решения информация содержится в комплексных РЛИ наблюдаемых целей. При этом обработка изображения заключается в вычислении корреляций его с детерминированной функцией отражения «блестящих точек» k -й цели $\hat{f}_{k\sigma}(\bar{x})$ и оценкой диффузионной составляющей $\bar{f}_p(\bar{x})$.

Получение полной информации, необходимой для реализации оптимального алгоритма, требует чрезвычайно большого объема наблюдаемых данных для формирования достоверного «радиолокационного портрета» и практически недостижимо в обозримом будущем, что приводит к необходимости разработки алгоритмов, требующих для своей реализации ограниченного объема априорной информации, с одной стороны, достаточно информативных, и, с другой стороны, доступных сравнительно неложными средствами.




Рис. 3.3. Вариант структурной схемы устройства формирования логарифма отношения правдоподобия

К устойчивым и достоверным сведениям о различиях распознаваемых пространственно-распределённых целей могут быть отнесены:

- а) данные о различиях в размерах (длине и ширине);
- б) данные о различиях в интегральной (общей) ЭПР.

Практически реализуемый «рабочий» алгоритм формирования статистик принятия решения не должен использовать индивидуальные радиолокационные портреты (распределения ЭПР «блестящих точек» и диффузионной составляющей по поверхности цели). Считая распределение ЭПР равномерным, приходим к следующему выражению статистики, которая составляет основу принятия решения по любому статистическому критерию

$$I_k = \int_{\Omega_k(j)} |F(\bar{x})|^2 d\bar{x}, \quad (3.2.28)$$

где подчеркнута зависимость области, занятой целью k -го класса от курса его наблюдения φ .

3.3. Адаптивный алгоритм классификации пространственно-распределённых целей по данным радиолокатора с синтезированной апертурой

Не изменяя общей методологии решения задачи классификации, ограничимся примером распознавания 3 классов ПРЦ.

Вывод алгоритма произведем при следующих предположениях:

1. РСА перемещается по прямолинейной траектории, использует импульсный широкополосный зондирующий сигнал, причем отсчеты РЛИ различных каналов дальности могут считаться статистически независимыми. В связи с этим все дальнейшие рассуждения проводятся для одного канала дальности. Обобщение алгоритма на все РЛИ производится естественным образом на заключительном этапе вывода алгоритма классификации.

2. Весь участок поверхности, попадающий в один канал дальности, разбит на отдельные элементарные участки, состоящие, в свою очередь, из большого числа элементарных отражателей. Каждый элементарный участок определяется своей координатой x_i ($i = \overline{1, I}$; I – общее число таких участков, расположенных в раскрые реальной диаграммы направленности). Сигнал, отраженный от такого участка, представляет собой

нормальный случайный процесс с нулевым математическим ожиданием и дисперсией $\sigma_m^2(x_i)$, которая зависит от целого ряда параметров, в первую очередь, от типа объекта, его индивидуальных особенностей, а также условий наблюдения. При обозначении мощности отраженного сигнала сохранен индекс « m », характеризующий ее зависимость от номера класса объекта. Названная функция как раз и является той зависимостью, значения которой отличают один класс наблюдаемой ПРЦ от другого (лес от поля, дорогу от пашни и т. п.). Основные геометрические соотношения показаны на рис. 3.4.




Рис. 3.4. Геометрия задачи

3. Сигналы, отраженные различными элементарными участками поверхности, созданы физически различными отражателями и поэтому с достаточным основанием могут считаться статистически независимыми.

4. Вектор признаков, используемых для классификации (размерность вектора совпадает с числом классов), представляет собой вектор достаточных статистик (отношений правдоподобия) или его модификации, применение которых связано с недостаточной априорной информацией о характеристиках наблюдаемых поверхностей.

С учетом принятых предположений комплексная амплитуда сигнала, принимаемого в n -й точке траектории от i -го элементарного участка поверхности с координатой x_i может быть записана в следующем виде:

$$U_n = \sum_{i=1}^I f_n^m(x_i) \exp(-j \pi_0 \tau_n(x_i)) + N_n, \quad (3.3.1)$$

где π_0 – несущая частота;

$\tau_n(x_i)$ – запаздывание сигнала, принимаемого в n -й точке траектории от i -го элементарного участка наблюдаемой поверхности;

$f_n^m(x_i)$ – комплексная амплитуда сигнала, формируемого i -м элементарным участком поверхности объекта m -го класса в n -й точке приема;

N_n – комплексная амплитуда n -го отсчёта шума.

Комплексная амплитуда (3.3.1) представляет собой выборочное значение нормальной случайной величины, имеющей следующие статистические характеристики:

$$M \{f_n^m(x_i)\} = 0; \quad (3.3.2)$$

$$M \{f_n^m(x_i) f_n^m(x_j)\} = \sigma_m^2(x_i) \delta_{ij}, \quad (3.3.3)$$

где δ_{ij} – символ Кронеккера;

$\sigma_m^2(x_i)$ – удельная ЭПР m -го класса ПРЦ как функция от координат поверхности.

Обозначая расстояние до центра наблюдаемого участка поверхности R_n , запишем величину запаздывания отраженного сигнала от i -го элементарного участка до n -й точки траектории:

$$\tau_n(x_i) = \frac{2}{C} \sqrt{R_n^2 + (r_n - x_i)^2} \approx \frac{2R_n}{C} \left[1 + \frac{(r_n - x_i)^2}{2R_n^2} \right], \quad (3.3.4)$$

где C – скорость света;

r_n – координата n -й точки приема отраженного сигнала.

Обобщая высказанные предположения, сформируем вектор наблюдаемых данных на выходе приемника локатора:

$$U = \beta f^k + N_{\text{ш}}, \quad (3.3.5)$$

где $\beta = (S(x_1), \dots, S(x_I))$ – матрица $(N_{\text{ш}} \times \mathbf{I})$, состоящая из векторов:

$$S(x_i) = \|S(x_i^n)\| = \left\| \exp \left(j \frac{2\pi}{\lambda R_i} r_n^2 - j \frac{4\pi}{\lambda R_i} x_i r_n \right) \right\|, \quad (3.3.6)$$

задающих фазовое распределение сигнала, отраженного от i -го элемента поверхности, по точкам синтезируемой апертуры, имеющим координаты r_n ($n = \overline{1, N_{\text{ш}}}$; $N_{\text{ш}}$ – число принимаемых импульсов); $f^k = \|f_i^k\| = \|f_n^k(x_i)\|$ – вектор комплексных амплитуд, размерность которого определяется числом отражающих элементарных участков поверхности; $N_{\text{ш}}$ – вектор отсчетов шума, имеющего следующие статистические характеристики:

$$M\{N_{\text{ш}}\} = 0; \quad 0,5M\{N_{\text{ш}} N_{\text{ш}}^T\} = R_{\text{ш}} = \sigma_{\text{ш}}^2 E,$$

где E – единичная матрица, а $\sigma_{\text{ш}}^2$ – дисперсия шума.

Для решения задачи классификации по какому-либо из статистических критериев: минимума среднего риска, максимума апостериорной плотности или максимального правдоподобия (этот критерий в дальнейшем будет принят в качестве основного) – необходимо записать отношение правдоподобия:

$$\Delta_k = \frac{p(U/\text{сигнал от цели } m\text{-го класса} + \text{шум})}{P(U/\text{шум})}, \quad (3.3.7)$$

где $P[U/.]$ – условная плотность вероятности наблюдения вектора U при наличии поверхности m -го класса и шума или только шума.

Считая вектор U гауссовским с нулевым математическим ожиданием, что соответствует предыдущим рассуждениям, запишем отношение правдоподобия:

$$\Lambda_k = \frac{1}{|E + \beta Q_k \beta^{*T}|} \exp \left(0,5 U^{*T} \left[R_{\text{ш}}^{-1} - R_{\text{сш}_m}^{-1} \right] U \right), \quad (3.3.8)$$

$$\text{где} \quad R_{\text{сш}_m} = \beta Q_k \beta^{*T} + R_{\text{ш}}; \quad (3.3.9)$$

$$Q_m = \begin{pmatrix} \sigma_{1m}^2 & & 0 \\ & \dots & \\ 0 & & \sigma_{lm}^2 \end{pmatrix}$$

– матрица мощностей сигналов от каждого из l элементарных участков, входящих в анализируемую поверхность m -го класса.

Учитывая специальный вид матрицы (3.3.9) и используя равенство Вудбери, запишем логарифм отношения правдоподобия в следующем виде:

$$\begin{aligned} l_m = \ln \Lambda_m = 0,5 U^{*T} R_{\text{ш}}^{-1} \left[E + Q_m \beta^{*T} R_{\text{ш}}^{-1} \beta \right]^{-1} \times \\ \times Q_m \beta^{*T} R_{\text{ш}}^{-1} U - Sp \ln \left(E + Q_m \beta^{*T} \right). \end{aligned} \quad (3.3.10)$$

Здесь

$$Q_k = \begin{pmatrix} \sigma_{1m}^2 / \sigma_{\text{ш}}^2 & & 0 \\ & \dots & \\ 0 & & \sigma_{lm}^2 / \sigma_{\text{ш}}^2 \end{pmatrix} = \begin{pmatrix} q_{1m} & & 0 \\ & \dots & \\ 0 & & q_{lm} \end{pmatrix}. \quad (3.3.11)$$

– диагональная матрица отношений мощностей сигналов от каждого i -го элементарного участка к мощности шума в одном импульсе.

Вводя новый вектор

$$F - \|F_i\| = \frac{1}{\sigma_{\text{ш}}} \beta^{*T} R_{\text{ш}}^{-1} U = \left\| \frac{1}{\sigma_{\text{ш}}} \sum_{n=1}^{N_{\text{ш}}} U_n \exp \left(-j \frac{2\pi}{\lambda R_{\text{H}}} r_n^2 + j \frac{4\pi}{\lambda R_{\text{H}}} r_n x_i \right) \right\|, \quad (3.3.12)$$

компоненты которого представляют собой отсчеты комплексных амплитуд РЛИ, для достаточной статистики (логарифма отношения правдоподобия) получаем выражение:

$$I_m = \ln \Lambda_m = 0,5 F^{*T} (E + Q_m \beta^{*T} \beta)^{-1} Q_m F - Sp \ln (E + \beta Q_m \beta^{*T}). \quad (3.3.13)$$

Считая размер элементарного участка поверхности равным размеру элемента разрешения по азимуту и пренебрегая влиянием соседних участков ($\beta^{*T} \beta \approx N_{\text{и}} E$)²³, получаем выражение достаточной статистики:

$$I_m = \sum_{i=1}^I \frac{q_{im}}{1 + q_{im}} \frac{|F_i|^2}{2} - \sum_{i=1}^I \ln(1 + q_{im}), \quad (3.3.14)$$

где q_{im} ($i = 1, \dots, I$; $m = 1, \dots, M$) – отношение сигнал/шум в i -м элементе разрешения после когерентного накопления $N_{\text{и}}$ отсчетов, M – число классов.

При известных априори «радиолокационных портретах» (векторах q_{im}) для каждого из классифицируемых типов поверхностей оптимальный алгоритм классификации состоит в том, чтобы вычислить достаточную статистику для каждого возможного m и выбрать максимальное значение.

$$\hat{m} = \arg \max_m \left\{ - \sum_{i=1}^I \left[\frac{1}{1 + q_{im}} \frac{|F_i|^2}{2} - \ln(1 + q_{im}) \right] \right\}. \quad (3.3.15)$$

Следует отметить, что радиолокационные портреты» (РП) для различающихся условий наблюдения, как правило, не известны практически ни для одной ПРЦ, что приводит к необходимости их оценки на этапе предварительного обучения. Соответственно алгоритм классификации имеет вид:

$$\hat{m} = \arg \max_m \left\{ \sum_{i=1}^I \frac{1}{1 + \hat{q}_{im}} \frac{|F_i|^2}{2} - \hat{C}_m \right\}. \quad (3.3.16)$$

где знак $\hat{}$ обозначает оценку соответствующего параметра на этапе предварительного обучения.

²³ Принятое условие означает, что мы учитываем только тот участок ПРЦ, который попадает в элемент разрешения РСА по азимуту.

Следует обратить особое внимание на тот факт, что достоверная оценка РП представляет собой очень сложную в организационном и вычислительном плане задачу, в первую очередь, из-за чрезвычайно большого объема факторов, влияющих на вид радиолокационного портрета. К таким факторам можно отнести зависимость РП от условий наблюдения (дальность, ракурс, длина волны, поляризация), погодных и климатических условий, времени суток и времени года, индивидуальных особенностей, конфигурации и электродинамических свойств наблюдаемых объектов. В то же время, очевидно, что в любом случае основой решения задачи классификации является вектор достаточных статистик

$$\bar{l} = \|l_m\| = \left\{ \sum_{i=1}^I \frac{|F_i|^2}{1 + \hat{q}_{im}} \right\}, \quad (3.3.17)$$

Этот вектор является оптимальным вектором признаков для формирования решающего пространства и принятия решения, так как константы $\hat{C}_m$ не зависят от наблюдаемых данных. Использование этого вектора представляет основу для классификации. Его следует применять на практике во все более возрастающей степени по мере создания банка радиолокационных портретов, полученных в разных условиях наблюдения.

Поскольку на этапе эскизного проектирования говорить о наличии представительного банка РП безусловно преждевременно, для синтеза алгоритма классификации приходится использовать те исходные данные о различии объектов, которые не вызывают сомнений и имеют ясное физическое обоснование. Такими робастными признаками являются размеры и общая ЭПР ПРЦ, в то время как индивидуальные (присущие конкретному участку поверхности) признаки, содержащиеся в РП цели, на этом этапе априори не известны. В тех случаях, когда какие-либо надежные сведения о распределении ЭПР по поверхности цели отсутствуют, целесообразно считать такое распределение равномерным с тем, чтобы ориентироваться на худшую ситуацию, ибо наличие индивидуальных особенностей, отличающих один класс от другого, не может, по крайней мере, потенциально ухудшить эффективность распознавания.

В этом случае при формировании весовых коэффициентов, зависящих от $\hat{q}_{im}$, не используется информация о «тонкой» структуре РП, но учитываются

априорные сведения об отличии классов объектов по размерам и ориентации областей, занимаемых «портретами» РПЦ на РЛИ. Названные области, в свою очередь, существенно зависят от условий наблюдения, в частности, оценок наклонной дальности и ракурса (при наличии).

В этом случае компоненты вектора $\bar{l}$ вычисляются путем суммирования отсчетов РЛИ в пределах области, зависящей от номера конкурирующей гипотезы:

$$l_m = \sum_{\Omega_m(\phi)} |F_i|^2. \quad (3.3.18)$$

Более подробно алгоритм выглядит следующим образом.

По наблюдаемому РЛИ, предъявленному к классификации, прежде всего, производятся две операции:

- оценка области, занятой элементами РПЦ на изображении, например, путем сравнения отсчетов с порогом, установленным по уровню шума;
- оценка ракурса $\hat{\phi}$, использующая только те отсчеты РЛИ, которые отнесены к цели по результатам предыдущей пороговой обработки.

Поскольку размерность вектора равна числу конкурирующих гипотез, при обучении необходимо моделировать T выборочных векторов l_t ($t = \overline{1, T}$) при задании объектов каждого из M классов, расположенных под ракурсом, величина которого оценивается по наблюдаемому РЛИ

$$l_t^{m_0} = |l_{tk}^{m_0}| = \left\| \sum_{\Omega_m(\phi)} |F_i|_{lm_0}^2 \right\|, \quad (3.3.19)$$

где $|F_i|_{lm_0}^2$ – i -й отсчет t -й обучающей выборки при условии, что объект относится к классу m_0 . Следует обратить внимание на отличие индексов m и m_0 . Первый из них – координата вектора, а второй – номер объекта, для которой производится моделирование выборочных отсчетов РЛИ $|F_i|_{lm_0}^2$ на этом этапе обучения.

В результате обучения формируются оценки векторов выборочных средних:

$$l^{m_0} = |l_k^{m_0}| = \left\| \frac{1}{T} \sum_{t=1}^T l_{tm}^{m_0} \right\|, \quad (3.3.20)$$

и выборочных дисперсий:

$$(\sigma^{m_0})^2 = |(\sigma_m^{m_0})^2| = \left\| \frac{1}{T} \sum_{t=1}^T (l_{tm}^{m_0} - l_m^{m_0})^2 \right\|. \quad (3.3.21)$$

Принятие решения производится по минимуму расстояния:

$$\hat{m}_0 = \arg \max_{m_0} \sqrt{\sum_{m=1}^M \frac{(l_m - l_m^{m_0})^2}{(\sigma_m^{m_0})^2}}. \quad (3.3.22)$$

Для иллюстрации работы предлагаемого алгоритма рассмотрим решение задачи классификации трёх объектов, отличающихся своими размерами $\Omega_1, \Omega_2, \Omega_3$.

Пусть наблюдаемая цель расположена в одном канале дальности, имеет одинаковую удельную ЭПР и отличается от других своими размерами, другими словами, количеством элементов разрешения, занятых РЛИ цели. Малая цель занимает N_M элементов, средняя – N_C и большая – N_B . Начало цели совместим с началом координат. На рис. 3.5 приведены зависимости удельной ЭПР $\sigma(i)$ от координат i .

Рассмотрим функционирование оптимального алгоритма вычисления признаков. Он вычисляет три числа $\lambda_M, \lambda_C, \lambda_B$, где

$$\lambda_M = \sum_{i=1}^{N_M} |F_i^2|; \quad \lambda_C = \sum_{i=1}^{N_C} |F_i^2|; \quad \lambda_B = \sum_{i=1}^{N_B} |F_i^2|.$$

При наблюдении «малой» цели все три числа имеют близкие значения (вторая и третья суммы отличаются от первой только суммированием шумовых отсчётов; при отсутствии шума (как на рис. 3.5) дополнительные числа просто равны нулю. При наблюдении «средней» цели первая сумма существенно не изменяется (суммируются те же числа, а вот вторая и третья заметно возрастают за счёт добавления сигнальных отсчётов. В случае наблюдения «большой» цели первая и вторая суммы существенно не изменяются, что и при наблюдении «средней» цели, а третья сумма возрастает (добавление сигнальных отсчётов). Указанные соображения иллюстрируются на рис. 3.5.




Рис. 3.5. Отсчёты РЛИ (случайные числа, распределённые по экспоненциальному закону

При достаточном отличии в размерах целей в признаковом пространстве образуются три сгруппированные области, характерных для наблюдения каждой из трёх целей (рис. 3.6). Далее решение принимается по одному из известных методов (минимум среднеквадратичного расстояния до центра, метод К ближайших соседей и т. п.).

Моделируя отдельные отсчёты в виде случайных чисел с экспоненциальным распределением (такое распределение имеют отсчёты мощности при исходном нормальном распределении на входе приёмника) и варьируя различие в размерах (средняя от малой, большая от средней отличаются по размерам на $\delta\%$), получаем зависимость вероятности ошибки от различия в размерах (рис. 3.7). Число отсчётов, приходящихся на «малую» цель, фиксировано и равно 5.

Рассмотренная методология построения алгоритма классификации ПРЦ, опирающаяся на понятие достаточной статистики, поскольку вектор достаточных статистик является оптимальным набором признаков, позволяет решить задачу классификации наилучшим образом в рамках критерия минимума среднего риска. В то же время формирование названного вектора наталкивается на практически непреодолимые трудности

из-за очень большой априорной неопределённости. В связи с этим целесообразно искать признаки классификации, начиная с вектора достаточных статистик, при его последовательном упрощении путём отказа от тех деталей и тонких особенностей, которые недоступны классификатору в условиях реальной работы.




Рис. 3.6. Группировка признаков ПРЦ трёх классов




Рис. 3.7. Вероятность правильной классификации в зависимости от различия в размерах ПРЦ

По данным РЛС методом искусственного синтезирования апертуры формируется радиолокационное изображение наблюдаемой цели. Полученный вектор отсчётов РЛИ умножается на M векторов, каждый из которых соответствует одному из возможных ожидаемых классов ПРЦ. В результате формируется вектор, размерность которого совпадает с числом классов и введ за этим определяется M расстояний между полученным вектором (вектором признаков) и M областями, полученными на этапе обучения. Каждая такая область сформирована вектором признаков, соответствующих каждому из M возможных классов ПРЦ.

Если различаемые гипотезы представляют собой РЛИ однородных поверхностей с различными отражающими свойствами (различными для отличающихся классов, но одинаковыми в пределах синтезированного участка наблюдения ЭПР), то есть $\sigma_m^2(x_i) = \sigma_m^2$ для всех $i = \overline{1, I}$, причём, число классов M считается известным, а значения σ_m^2 неизвестны, применяется непараметрическое правило классификации, заключающееся в сравнении оценки плотности вероятности (гистограммы) случайной величины $l = \sum |F_i|^2$ с полученными на этапе обучения m оценками плотностей вероятности соответствующих случайных величин (сумм квадратов амплитуды) для каждого из возможных M классов поверхностей, расположенных на траектории прогнозируемого полёта ЛА.

3.4. Алгоритмы автоматического группирования данных

3.4.1. Чёткая и нечёткая декомпозиции

Достаточно вернуться к анализу результатов предыдущего раздела (рис. 3.6 и комментарии к нему), чтобы убедиться в том, что в основе принятия решения в пространстве оптимальных или близких к оптимальным признаков лежит группирование данных, цель которого заключается в декомпозиции множества признаков на группы однотипных (принадлежащих к одному классу) элементов.

При выборе алгоритма группирования (декомпозиции) следует руководствоваться двумя принципами: гомогенность в группах – в пределах одной группы данные (признаки) должны быть как можно более похожи друг на друга и гетерогенность между группами – данные, принадлежащие различным группам, должны максимально отличаться друг от друга.

Наиболее подходящей мерой подобия данных следует считать расстояние между признаками, например, меру Евклида и т.п. В то же время следует иметь в виду, что при использовании различных мер подобия можно получить группы различной структуры. Пример группирования данных в двумерном пространстве приведён на рис. 3.8.

Перед нами стоит задача декомпозировать данные, представленные n -мерными векторами $x_k = \{x_{k1}, ..., x_{kn}\}$, где $k = 1, 2, ..., M$ – номер класса ПРЦ. Проводя аналогию с предыдущей задачей, $M = 3$ – число классов распознаваемых ПРЦ, а n – число обучающих выборок, каждая из которых формирует вектор признаков (достаточных статистик). Множество $\mathbf{M}$ векторов образует матрицу $\mathbf{n} \times \mathbf{M}$

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{M1} \\ \vdots & \ddots & \vdots \\ x_{1n} & \cdots & x_{Mn} \end{pmatrix}. \quad (3.4.1).$$



Рис. 3.8. Группировка данных

Столбцы представляют собой объекты, другими словами, пространственно-распределённые цели – ПРЦ, а строки – коэффициенты отношения правдоподобия.

Следует подчеркнуть, что все возможные декомпозиции M объектов на L групп представляют собой достаточно большое число, равное

$$\frac{1}{L!} \sum_{i=1}^L \binom{L}{i} (-1)^{(L-i)} i^M. \quad (3.4.2)$$

При $M = 100$ и $L = 5$ количество возможных декомпозиций (3.4.2) равно очень большому числу $6,57 \cdot 10^{67}$. Поэтому решающую роль играет метод оптимальной декомпозиции, не требующий перебора всех возможных результатов группирования.

В задачах группирования данных различают три типа декомпозиции: чёткие, нечёткие и возможные, причём последние являются модификацией нечётких [8].

При чётком группировании объект точно принадлежит или не принадлежит к конкретной группе. Цель группирования заключается в декомпозиции данных на L групп так, чтобы все векторы были распределены по группам, группы не пересекались и ни одна из групп не была пустой, и ни одна группа не содержала всего множества данных. Рассмотрим данные на рис. 3.9.




Рис. 3.9. Пример данных

Чёткая декомпозиция этих данных ($M = 10$) на 3 группы ($L = 3$) может быть представлена следующей матрицей U :

$$U = \begin{bmatrix} 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 0 \end{bmatrix}, \quad (3.4.3)$$

Отметим, что ПРЦ x_{10} отнесена ко второй группе, хотя, если судить по рисунку, она должна образовывать новый класс. Но по условию задачи классов должно быть три и объектов, не отнесённых к одному из этих трёх классов, быть не должно.

Это тот случай, когда требуется расширение чёткой композиции, так как в реальных задачах мы не всегда можем отнести ПРЦ к единственной категории. Например, границы между РЛИ малых, средних и больших кораблей точно определить невозможно. В таких случаях существуют два вида декомпозиции: нечёткая и возможная [8]. В этих двух случаях ПРЦ могут входить в произвольное число групп со степенью принадлежности, измеряемой числом из интервала $[0,1]$. При этом выдвигается дополнительное ограничение: сумма членов каждого столбца матрицы U должна равняться 1. Поэтому такую декомпозицию часто называют вероятностной. В этом случае матрица (3.4.3) может выглядеть следующим образом:

$$U = \begin{bmatrix} 1 & 0,89 & 0,93 & 0,01 & 0,01 & 0,00 & 0,01 & 0,01 & 0,00 & 0,33 \\ 0 & 0,06 & 0,02 & 0,98 & 0,98 & 0,99 & 0,01 & 0,01 & 0,00 & 0,29 \\ 0 & 0,05 & 0,05 & 0,01 & 0,01 & 0,01 & 0,98 & 0,98 & 1 & 0,38 \end{bmatrix}. \quad (3.4.4)$$

Пример матрицы (3.4.4) позволяет интерпретировать ПРЦ x_{10} как объект с примерно одинаковыми степенями принадлежности ко всем трём группам. Интуитивно мы приписали бы этому объекту малые веса принадлежности к любой из трёх групп, относя его к шуму. Однако, при этом не выполняется условие нормировки. В этих случаях используется, так называемая, возможная декомпозиция, представленная следующей матрицей:

$$U = \begin{bmatrix} 0,87 & 0,44 & 0,79 & 0,04 & 0,03 & 0,03 & 0,05 & 0,04 & 0,05 & 0,12 \\ 0,01 & 0,02 & 0,01 & 0,52 & 0,39 & 0,87 & 0,01 & 0,01 & 0,01 & 0,03 \\ 0,01 & 0,01 & 0,02 & 0,01 & 0,01 & 0,01 & 0,53 & 0,63 & 0,79 & 0,03 \end{bmatrix}. \quad (3.4.5)$$

В этом случае ПРЦ x_{10} входит во все группы, но с малой степенью принадлежности.

Основным фактором, определяющим декомпозицию данных, является способ определения расстояния между признаками. Наиболее распространённой мерой удалённости служит мера Евклида D_{id} , интерпретируемая как геометрическое расстояние между двумя точками $x_d = [x_{d1}, \dots, x_{dn}]$ и $y_i = [y_{i1}, \dots, y_{in}]$:

$$D_{id} = \sqrt{\sum_{j=1}^n (x_{dj} - y_{ij})^2} = x_d - y_i^2. \quad (3.4.6)$$

Обобщением меры Евклида является метрика Минковского:

$$D_{id} = \left(\sum_{j=1}^n |x_{dj} - y_{ij}|^r \right)^{\frac{1}{r}}. \quad (3.4.7)$$

При $r = 1$ из меры Минковского следует мера Манхеттен, которая может интерпретироваться как расстояние, полученное перемещением под прямыми углами. Для иллюстрации мер Евклида и Манхеттен на рис. 3.10 показаны названные расстояния между двумя точками x_1 и x_2 .




Рис. 3.10. Расстояния Евклида и Манхеттен

При использовании двоичных переменных мера Манхеттен превращается в меру Хемминга, которая указывает количество битов, отличающих координаты двух точек.

3.4.2. Алгоритмы декомпозиции

Алгоритм HCM (Hard C-Means) однозначно декомпозирует данные на L групп. В процессе выполнения алгоритма рассчитываются удалённости каждого вектора x_k , $k = 1, \dots, M$, от центров групп v_i $i = 1, \dots, L$. Принадлежность к группе описывается с помощью матрицы U , элементы которой равны 1, если элемент принадлежит к группе или 0, если не принадлежит. Алгоритм содержит следующие этапы:

1. Выбор числа групп L и указание положений их центров.
2. Определение принадлежности элемента к группе по удалённости от выбранного центра.
3. Определение новых центров.
4. Проверка условия завершения выполнения. При невыполнении условия возвращение к этапу 2.

Условием завершения может служить малое изменение значений матрицы U , а именно, $\|U^{(t+1)} - U^{(t)}\| < \varepsilon$, где ε – априори заданная константа. Блок-схема алгоритма приведена на рис. 3.11.

Алгоритм FCM (Fuzzy C-Means) даёт возможность образовать группы из элементов с разными степенями принадлежности, при этом один и тот же элемент может входить в несколько групп с разными весами соответствия названным группам. Этот алгоритм предназначен для нечёткого группирования данных. Идея алгоритма заключается в минимизации критерия

$$J(X; U; V) = \sum_{i=1}^L \sum_{k=1}^M (\mu_{ik})^m \|x_k - v_i\|^2, \quad (3.4.8)$$

причём

$U = [\mu_{ik}]$ – матрица декомпозиции, элементы которой – суть степень принадлежности признака той или иной группе;

$V = [v_1, v_2, \dots, v_L]$ – матрица центров кластеров, которые должны быть определены в итоге работы алгоритма;

m – коэффициент, характеризующий степень нечёткости групп данных. На практике выбирают $m = 2$.




Рис. 3.11. Алгоритм HCM

Для выполнения алгоритма необходимо выбрать количество групп L , степень нечёткости m , параметр остановки – ε , а также случайным образом инициировать матрицу $U^{(0)}$ и вектор прототипов групп $V^{(0)}$. Блок схема выполнения алгоритма представлена на рис. 3.12.

При отказе от выполнения условия нормировки столбцов матрицы U (сумма степеней принадлежности обязательно равна 1) может быть

использован алгоритм PCM (Possibilistic C-Means), который минимизирует целевую функцию

$$J(X; U; V) = \sum_{i=1}^L \sum_{k=1}^M (\mu_{ik})^m |x_k - v_i|^2 + \sum_{i=1}^L \eta_i \sum_{k=1}^M (1 - \mu_{ik})^m, \quad (3.4.9)$$

где η_i – положительная константа.




Рис. 3.12. Алгоритм FCM

Блок схема алгоритма показана на рис. 3.13.




Рис. 3.13. Алгоритм PCM

Проведём сравнительный анализ алгоритмов HCM, PCM и FCM. На рис. 3.14 представлено множество данных, состоящее из девяти двухмерных объектов ($M = 9$ и $n = 2$). Соответствующая этому множеству матрица $\mathbf{X}$ имеет вид:

$$\mathbf{X} = \begin{bmatrix} 98 & 97 & 111 & 109 & 178 & 178 & 190 & 189 & 143 \\ 86 & 99 & 99 & 85 & 85 & 95 & 97 & 85 & 46 \end{bmatrix}.$$




Рис. 3.14. Пример группировки

Нетрудно заметить две группы объектов и индивидуально расположенный объект №9, не подходящий ни к одной группе. Символом «+» обозначены центры групп, найденные алгоритмом HCM. Объект №9 отнесён ко второй группе, и центр группы сместился к объекту №9. В результате сформирована матрица декомпозиции

$$U_{\text{HCM}} = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (3.4.10)$$

Алгоритм FCM приписал объект №9 к обеим группам с одинаковой степенью принадлежности, равной 0,5. В этом случае центры обеих групп смещены к объекту №9. В результате группирования названным алгоритмом сформирована матрица декомпозиции

$$U_{\text{FCM}} = \begin{bmatrix} 0,99 & 0,98 & 0,98 & 0,99 & 0,00 & 0,01 & 0,02 & 0,01 & 0,50 \\ 0,01 & 0,02 & 0,02 & 0,01 & 1,00 & 0,99 & 0,98 & 0,99 & 0,50 \end{bmatrix}. \quad (3.4.11)$$

Лучше всего с проблемой шума справился алгоритм РСМ который «оценил» принадлежность объекта №9 к первой и второй группам со степенью принадлежности 0,04 и 0,03. В результате была сформирована матрица декомпозиции

$$U_{PCM} = \begin{bmatrix} 0,76 & 0,56 & 0,53 & 0,73 & 0,03 & 0,03 & 0,02 & 0,02 & 0,04 \\ 0,02 & 0,02 & 0,02 & 0,02 & 0,74 & 0,73 & 0,54 & 0,65 & 0,03 \end{bmatrix}. \quad (3.4.12)$$

Центры групп сместились незначительно. Отсюда следует вывод о целесообразности использования алгоритма РСМ в случае сравнительно более интенсивного шума.

3.5. Литература к главе 3

1. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА. М.: Издательский дом Академии Естествознания, 2017. 212 с.
2. Радиолокационные станции обзора Земли / под ред. Г.С. Кондратенкова. М.: Радио и связь, 1983. 271 с.
3. Доросинский Л.Г. Классификация радиолокационных изображений / Л.Г. Доросинский // Межд. конф. Теория и техника передачи, приема и обработки информации. /ХТУРЭ. Туапсе 1995. 104 с.
4. Радиолокационные станции с цифровым синтезированием апертуры антенны / под ред. В.Т. Горяинова. М.: Радио и связь, 1988. 304 с.
5. Ван Трис Г. Теория обнаружения, оценок и модуляции: в 3 т. / Г. Ван Трис. М.: Сов. радио, 1972. т. 1. 744 с.
6. Растринин Л.А. Метод коллективного распознавания / Л.А. Растринин, Р.Х. Эринштейн. М.: Энергоиздат, 1981. 80 с.
7. Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт; пер с англ. В.Л. Стефанюка. М.: Мир, 1976. 511 с.
8. Рутковский Л. Методы и технологии искусственного интеллекта / пер. с польского И.Д. Рудинского. М.: Горячая линия – Телеком. 2010. 520 с.

4. АНАЛИЗ АЛГОРИТМОВ КЛАССИФИКАЦИИ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ

В данной главе предлагаются методы определения эффективности алгоритмов классификации ПРЦ, основанные на определении вероятностей правильного и ошибочного распознавания классов ПРЦ с помощью аналитических выражений и/или статистического моделирования. Проблема анализа эффективности классификации включает решение трех основных задач, а именно [7, 8]:

1. Разработка методики расчета потенциальной точности классификации (разделы 4.1 и 4.2).
2. Разработка методики расчета вероятностей ошибочных и правильных решений по РЛИ ПРЦ (4.3 и 4.4).
3. Статистическое моделирование (4.5 и 4.6).

4.1. Границы Чернова и Кайлата – метод определения потенциальных возможностей классификации ПРЦ по вектору наблюдаемых данных

Потенциальные возможности решения задачи классификации будем оценивать вероятностями правильных ($P_{\text{пр}}$) и ошибочных ($P_{\text{ош}}$) решений, для которых получим граничные соотношения (истинные значения лежат в пределах указанных границ) с помощью известных для различения двух гипотез граничных соотношений Чернова и Кайлата [1, 2, 7].

При проверке $(M + 1)$ гипотез о классе наблюдаемой ПРЦ вероятность вынесения ошибочного решения равна:

$$P_{\text{ош}} = \sum_{i=1}^{M+1} p_i \sum_{\substack{j=1 \\ j \neq i}}^{M+1} p(j/i), \quad (4.1.1)$$

где p_i – априорная вероятность i -й гипотезы,

$p(j/i)$ – вероятность принятия решения о справедливости j -й гипотезы в том случае, когда истинной является i -я гипотеза.

Из (4.1.1) следует:

$$P_{\text{ош}} = \sum_{i=1}^M \sum_{j=i+1}^{M+1} [p_i p(j/i) + p_j p(i/j)]. \quad (4.1.2)$$

При этом верхняя граница ошибки (4.1.2) при проверке многих гипотез может быть получена с использованием методики [1]:

$$P_{\text{ош}} \leq \sum_{i=1}^M \sum_{j=i+1}^{M+1} [p_i Ch_{ij}^F + p_j Ch_{ij}^M], \quad (4.1.3)$$

где Ch_{ij}^F и Ch_{ij}^M – границы Чернова для вероятностей ложной тревоги и пропуска цели при проверке пары гипотез i и j независимо от остальных гипотез.

Далее получим выражение для нижней границы, вероятностей ошибок, известную для двух гипотез, как граница Кайлата [3].

Ошибка возникает, если хотя бы для одной из альтернативных гипотез выполняется неравенство:

$$l_{ij} > l_{ii} \quad (i \neq j), \quad (4.1.4)$$

в котором

$$l_{ij} = \ln \left(\frac{W_j(U)}{W_i(U)} \right). \quad (4.1.5)$$

– логарифм отношения правдоподобия при проверке пары гипотез с номерами j и i ; $W_j(U)$ и $W_i(U)$ – плотности распределения вероятностей значений вектора наблюдаемых данных U по гипотезам j и i . Пусть событие A_j соответствует выполнению условия (4.1.4). Тогда вероятность ошибки при наблюдении i -го класса целей представляется как вероятность суммы событий:

$$\sum_{\substack{j=1 \\ j \neq i}}^{M+1} P(j/i) = P \left[\sum_{\substack{j=1 \\ j \neq i}}^{M+1} A_j \right]. \quad (4.1.6)$$

Используя формулу для определения вероятности суммы зависимых событий [4], можно убедиться в справедливости неравенства:

$$P \left[\sum_{\substack{j=1 \\ j \neq i}}^{M+1} A_j \right] \geq \max_{\substack{j \\ j \neq i}} P[A_j]. \quad (4.1.7)$$

В этом выражении $p[A_j]$ представляет собой вероятность вынесения решения в пользу j -го класса целей при условии, что истинной является цель i -го класса при проверке только этой пары альтернатив. Обозначая эту вероятность $P_2(j/i)$ и используя (4.1.7), для вероятности ошибки (4.1.1) запишем неравенство:

$$P_{\text{ош}} \geq \sum_{i=1}^{M+1} P_i P_2(j/i). \quad (4.1.8)$$

где на значение j наложено единственное ограничение:

$$j \neq i. \quad (4.1.9)$$

Неравенство (4.1.8) позволяет оценить нижнюю границу вероятности ошибки в случае проверки более двух гипотез. Найдём решение для трёх классов

Используя (4.1.8) и (4.1.9), запишем два очевидных неравенства:

$$\begin{aligned} P_{\text{ош}} &\geq P_1 P_2(2/1) + P_2 P_2(3/2) + P_3 P_2(1/3), \\ P_{\text{ош}} &\geq P_1 P_2(3/1) + P_2 P_2(1/2) + P_3 P_2(2/3). \end{aligned} \quad (4.1.10)$$

Суммируя правые и левые части этих неравенств, получим:

$$P_{\text{ош}} \geq 0,5 \sum_{i=1}^2 \sum_{j=i+1}^3 [P_i P_2(j/i) + P_j P_2(i/j)]. \quad (4.1.11)$$

Учитывая, что:

$$P_i + P_j \neq 1. \quad (4.1.12)$$

и используя критерий минимума ошибки, для ситуации, изображённой на рис. 4.1, получим:

$$\begin{aligned} \int P_i W_i(U) dU &= P_i = A + C + D; \\ \int P_j W_j(U) dU &= P_j = B + C + D. \end{aligned} \quad (4.1.13)$$

Суммируя их, имеем:

$$A + B + 2(C + D) = P_i + P_j \quad (4.1.14)$$

Нетрудно заметить, что:

$$A + B = \int |P_i W_i(U) - P_j W_j(U)| dU. \quad (4.1.15)$$




Рис. 4.1. К вопросу о нижней границе вероятности ошибки

Отсюда, искомая вероятность ошибки равна:

$$C + D = 0,5 \left\{ P_i + P_j - \int |P_i W_i(U) - P_j W_j(U)| dU \right\}. \quad (4.1.16)$$

Для оценки интеграла (3.1.15) применим неравенство Шварца [4]:

$$\begin{aligned} \left[\int |P_i W_i(U) - P_j W_j(U)| dU \right]^2 &\leq \left\{ \int \left[P_i W_i(U) \right]^{\frac{1}{2}} - \left[P_j W_j(U) \right]^{\frac{1}{2}} dU \right\}^2 \times \\ &\times \left\{ \int \left[P_i W_i(U) \right]^{\frac{1}{2}} + \left[P_j W_j(U) \right]^{\frac{1}{2}} dU \right\}. \end{aligned} \quad (4.1.17)$$

После преобразования правой части (3.1.17) получим:

$$(A + B)^2 \leq (P_i + P_j)^2 - 4 \left\{ (P_i P_j)^{1/2} \int [W_i(U) W_j(U)]^{1/2} dU \right\}. \quad (4.1.18)$$

Следовательно

$$P_i P_2(j/i) + P_j P_2(i/j) = C + D \geq Kl_{ij}, \quad (4.1.19)$$

$$\text{где } Kl_{ij} = 0,5 \left\{ P_i + P_j - \sqrt{(P_i + P_j)^2 - 4 \left[(P_i P_j)^{1/2} \int [W_i(U) W_j(U)]^{1/2} dU \right]^2} \right\}. \quad (4.1.20)$$

Это выражение можно представить в виде:

$$Kl_{ij} = 0,5 \left\{ P_i + P_j - \sqrt{(P_i + P_j)^2 - 4 \left\{ (P_i P_j)^{1/2} \exp[\mu_{ij}(0,5)] \right\}^2} \right\}, \quad (4.1.21)$$

где
$$\mu_{ij}(s) = \ln \left(\int_{-\infty}^{\infty} [W_j(U)]^s [W_i(U)]^{1-s} dU \right). \quad (4.1.22)$$

Окончательно для (4.1.11) имеем:

$$P_{\text{ош}} \geq 0,5 \sum_{i=1}^2 \sum_{j=i+1}^3 Kl_{ij}. \quad (4.1.23)$$

При проверке $M + 1$ гипотез имеем:

$$P_{\text{ош}} \geq \frac{1}{M} \sum_{i=1}^M \sum_{j=i+1}^{M+1} Kl_{ij}. \quad (4.1.24)$$

Если наблюдаемые данные имеют векторный характер, изменения затрагивают только выражение (4.1.22) для логарифма производящей функции моментов, которое принимает следующий вид:

$$\mu_{ij}(s) = \ln \left(\int_{-\infty}^{\infty} [W_j(U)]^s [W_i(U)]^{1-s} dU \right). \quad (4.1.25)$$

Применяя методику [5] получим: имеем:

$$Ch_{ij}^F = Ch_{ij}^{F1} - Ch_{ij}^{F2} \frac{\gamma_3}{6}; \quad (4.1.26)$$

$$Ch_{ij}^M = Ch_{ij}^{M1} - Ch_{ij}^{M2} \frac{\gamma_3}{6}, \quad (4.1.27)$$

где
$$Ch_{ij}^{F1} = \exp[\mu_{ij}(s) - s\dot{\mu}_{ij}(s)] I_0 \left[s \sqrt{\dot{\mu}_{ij}(s)} \right]; \quad (4.1.28)$$

$$Ch_{ij}^{M1} = \exp[\mu_{ij}(s) - (1-s)\dot{\mu}_{ij}(s)] I_0 \left[(1-s) \sqrt{\dot{\mu}_{ij}(s)} \right]; \quad (4.1.29)$$

$$Ch_{ij}^{F2} = \exp[\mu_{ij}(s) - s\dot{\mu}_{ij}(s)] \times \\ \times \left\{ \left[s\sqrt{\ddot{\mu}_{ij}(s)} \right]^3 I_0 \left[s\sqrt{\ddot{\mu}_{ij}(s)} \right] + \frac{1}{(2\pi)^{1/2}} \left[1 - s^2 \mu_{ij}(s) \right] \right\}; \quad (4.1.30)$$

$$Ch_{ij}^{M2} = \exp[\mu_{ij}(s) + (1-s)\dot{\mu}_{ij}(s)] \times \\ \times \left\{ \left[(1-s)^2 \ddot{\mu}_{ij}(s) - 1 \right] \frac{1}{(2\pi)^2} - \left[(1-s)\sqrt{\ddot{\mu}_{ij}(s)} \right]^3 I_0 \left[(1-s)\sqrt{\ddot{\mu}_{ij}(s)} \right] \right\}; \quad (4.1.31)$$

$$\gamma_3 = \frac{\mu_{ij}^{(3)}(s)}{\left[\sqrt{\ddot{\mu}_{ij}(s)} \right]^3}; \quad (4.1.32)$$

$$I(\alpha) = \exp\left(\frac{\alpha^2}{2}\right) \frac{1}{(2\pi)^{1/2}} \int_{\alpha}^{\infty} \exp\left(-\frac{t^2}{2}\right) dt. \quad (4.1.33)$$

Значение аргумента s в (4.1.29)–(4.1.32) находится путем решения уравнения

$$\dot{\mu}_{ij}(s) = \ln \frac{P_i}{P_j}. \quad (4.1.34)$$

Если вектор наблюдаемых данных U представляет собой совокупность комплексных гауссовских отсчетов с нулевыми средними значениями для $\mu_{ij}(s)$ может быть получено следующее выражение:

$$\mu_{ij}(s) = (s-1) \ln[R_i] + s \ln[R_j] - \ln \left\{ \left[sR_j^{-1} - (1-s)R_i^{-1} \right] \right\}. \quad (4.1.35)$$

где R_i и R_j – корреляционные матрицы вектора Y по гипотезам i и j соответственно. Разложим эрмитову матрицу R_j на множители по Холецкому:

$$R_j = L_j L_j^*. \quad (4.1.36)$$

где L_j – нижняя (левая) треугольная матрица, а символ $*$ обозначает эрмитово сопряжение.

При этом выражение (3.1.35) может быть представлено в виде:

$$\mu_{ij}(s) = \sum_k \left[s \ln \lambda_k^{ij} - \ln(s \lambda_k^{ij} + 1 - s) \right], \quad (4.1.37)$$

где λ_k^{ij} – k -ое собственное значение матрицы:

$$K_{ij} = L_j^{-1} R_i (L_j^*)^{-1}. \quad (4.1.38)$$

Искомые производные функции $\mu_{ij}(s)$ имеют вид:

$$\dot{\mu}_{ij}(s) = \sum_k \left[\ln \lambda_k^{ij} - \frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]; \quad (4.1.39)$$

$$\ddot{\mu}_{ij}(s) = \sum_k \left[\frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]^2; \quad (4.1.40)$$

$$\ddot{\mu}_{ij}(s) = -2 \sum_k \left[\frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]^3. \quad (4.1.41)$$

Таким образом, для определения ошибок необходимо знание корреляционной матрицы отсчетов РЛИ, получаемого в отдельной p -й РЛС системы при наблюдении k -й цели.

РЛИ цели можно представить в виде суммы трех составляющих: шумовой

$$F_{pN}(\bar{p}/\bar{x}^0, \bar{x}) = \int E_p^*(\bar{p}, t/\bar{x}^0, \bar{x}) S_p^*(\bar{p}, t/\bar{x}^0, \bar{x}) G_p(\bar{p}, t/\bar{x}^0, \bar{x}) N_p(t) dt, \quad (4.1.42)$$

диффузионной

$$F_{pk}^0(\bar{p}/\bar{x}^0, x) = U_{kp} \int \Phi_p(\bar{p}, \bar{x}) f_{k0}^p(\bar{x}) d\bar{x} \quad (4.1.43)$$

и составляющей, вызванной наличием «блестящих точек» в составе модели ПРЦ k -го класса:

$$F_{pk}^1(\bar{p}/\bar{x}^0, \bar{x}) = U_{kp} \sum_i \Phi_p(\bar{p}, \bar{p}_{ki}^p) f_{ki}^p \quad (4.1.44)$$

Эти составляющие независимы между собой, и, следовательно, элементы искомой корреляционной матрицы представимы в виде суммы:

$$\|R_{pk}\|_{lm} = \|R_{pN}\|_{lm} + \|R_{pk}^0\|_{lm} + \|R_{pk}^1\|_{lm}, \quad (4.1.45)$$

$$\text{где} \quad \|R_{pN}\|_{lm} = N_{p0} \Phi_p^0(\bar{p}_l, \bar{p}_m); \quad (4.1.46)$$

$$\|R_{pk}^0\|_{lm} = U_{kp}^2 \int [\sigma_{ko}^p(\bar{x})]^2 \Phi_p(\bar{p}_l, \bar{x}) \Phi_p^*(\bar{p}_m, \bar{x}) d\bar{x}; \quad (4.1.47)$$

$$\|R_{pk}^1\|_{lm} = U^2 \sum \Phi_p(\bar{p}_l, \bar{p}_{ki}^p) \Phi_p(\bar{p}_m, \bar{p}_{ki}^p) [\sigma_{ki}^p]^2. \quad (4.1.48)$$

Дискретные значения $\bar{p}_l$ и $\bar{p}_m$ задают координаты отсчетов РЛИ на плоскости изображения.

Вводя нормированные функции неопределенности Φ_{pH}^0 и Φ_{pH} и пренебрегая константами, не влияющими на вычисление функции $\mu_{ij}(s)$ и ее производных, выражение (4.1.45) можно представить в следующем виде:

$$\begin{aligned} \|R_{pk}\|_{lm} = & q_{kp} (2N_{\text{ИР}} + 1) \int [\sigma_{k0}^p(\bar{x})]^2 \Phi_{pH}(\bar{p}_l, \bar{x}) \Phi_{pH}(\bar{p}_m, \bar{x}) d\bar{x} + \\ & + q_{kp} (2N_{\text{ИР}} + 1) \sum_i [\sigma_{ki}^p]^2 \Phi_{pH}^2(\bar{p}_l, \bar{p}_{ki}^p) \Phi_{pH}^*(\bar{p}_m, \bar{p}_{ki}^p) + \Phi_{pH}^0(p_l, p_m), \end{aligned} \quad (4.1.49)$$

$$\text{где} \quad q_{kp} = \frac{2P_{p0} \lambda_p^2 G_{lp} G_{2p} (\sigma_{ke}^p)^2 \tau_p}{(4\pi)^3 N_{p0} R_{lp}^2 R_{2p}^2}. \quad (4.1.50)$$

представляет собой эквивалентное отношение энергии сигнала к спектральной плотности шума в импульсе для случая наблюдения точечного отражателя с ЭПР, равной суммарной ЭПР цели $(\sigma_{ke}^p)^2$, при расположении его в точке, соответствующей центру цели. Выражение

$$q_{ke}^p = q_{kp} (2N_{\text{И}} + 1) \quad (4.1.51)$$

следует рассматривать как суммарное отношение сигнал/шум по пачке из $(2N_{\text{И}} + 1)$ импульсов

4.2. Анализ потенциальных характеристик классификации ПРЦ по вектору наблюдаемых данных

Примером анализа служит отыскание границ, полученных в предыдущем разделе, в случае наблюдения трёх классов ПРЦ, отличающихся размерами и суммарной ЭПР. Суммарная ЭПР каждой цели считается равномерно распределённой по поверхности ПРЦ, которая представляет собой прямоугольник. В качестве эталонов для каждого класса используются их «средние» представители: цель $N1$ («большая цель») размером 360×30 м, цель $N2$ («средняя цель») – 240×20 м и цель $N3$ («малая цель») – 120×10 м. Ракурс наблюдения для всех ПРЦ считается одинаковым и равным 90° . Будем считать, мощности сигналов, отраженных от целей разных классов при наблюдении под одинаковыми ракурсами, отличаются ориентировочно на 3 дБ. Предположим, что разрешающая способность РСА по азимуту и дальности одинакова, т. е.

$$Dx = Dy \quad (4.2.1)$$

При этом условии обеспечивается равенство масштабов формируемого РЛИ.




Рис. 4.2. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от суммарного отношения сигнал/шум (для цели 2-го класса; цели 1-го и 3-го классов отличаются на ± 3 дБ)

На рис. 4.2 приведены зависимости верхней

$$P_{\text{пп}} = 1 - 0,5 \sum_{i=1}^2 \sum_{j=i+1}^3 Kl_{ij} \quad (4.2.2)$$

и нижней

$$P_{\text{пп}} = 1 - \sum_{i=1}^2 \sum_{j=i+1}^3 (P_i Ch_{ij}^p + P_j Ch_{ij}^M) \quad (4.2.3)$$

границ вероятности правильного распознавания от суммарного отношения сигнал/шум для цели $N2(q_{2e})$ при различных значениях разрешения. Отношения сигнал/шум для двух других целей отличаются на 3 дБ:

$$q_{1e} = q_{2e} + 3 \text{ дБ}; \quad q_{3e} = q_{2e} - 3 \text{ дБ}. \quad (4.2.4)$$

Анализ влияния разрешения на качество распознавания демонстрирует рис. 4.3,




Рис. 4.3. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном суммарном отношении сигнал/шум)

В случае фиксированного отношения сигнал/шум в каждом импульсе (без ограничений общей энергетики пачки) вероятность правильной классификации так же существенно зависит от разрешающей способности (рис. 4.4).




Рис. 4.4. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном отношении сигнал/шум в импульсе)




Рис. 4.5. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном суммарном отношении сигнал/шум)

Влияние различий в ЭПР и размерах ПРЦ на эффективность их классификации иллюстрируется на рис. 4.5–4.9. На рис. 4.6 и 4.7 приведены зависимости вероятности правильного распознавания от разницы в линейных размерах ПРЦ, выраженной в долях по отношению к размеру цели 2-го класса (Δ) при разрешении 30 и 10 м. Размеры (L – длина, S – ширина) целей определяются равенствами:




Рис. 4.6. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в размерах целей (при фиксированном значении суммарного отношения сигнал/шум)




Рис. 4.7. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в размерах целей (при фиксированном значении суммарного отношения сигнал/шум)




Рис. 4.8. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в суммарной ЭПР целей (при фиксированных значениях суммарного отношения сигнал/шум; цели не отличаются размерами)




Рис. 4.9. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в суммарной ЭПР целей (при фиксированных значениях суммарного отношения сигнал/шум; цели отличаются размерами)

4.3. Методика расчета эффективности классификации ПРЦ по радиолокационному портрету

4.3.1. Проблема анализа эффективности алгоритмов классификации

В качестве основного метода классификации, разумно сочетающего близость к оптимальному с относительно простой технической реализацией, может быть использован следующий алгоритм, предложенный в главе 2. В качестве решения принимается гипотеза о классе с номером $\hat{k}$, для которого выполняется соотношение:

$$\hat{k} = \underset{k}{\operatorname{argmin}} l(k) = \underset{k}{\operatorname{argmin}} \left\{ \sum_{i \in \Omega_k} \left[\frac{\eta_i}{\xi_i^k} + \ln \xi_i^k \right] \right\}, \quad (4.3.1)$$

где $\eta_i = |F_i|^2$ – i -й отсчет РЛИ наблюдаемого ПРЦ,

$\xi_i^k = 1 + \hat{q}_i$ – i -й отсчет ожидаемого значения ЭПР (радиолокационного портрета) цели k -го класса.

Вероятность принятия решения о справедливости k -й гипотезы при условии, что истинна 1-я, определяется выражением:

$$P(k/l) = \int_G \sigma(\gamma_k / \bar{\eta}) P(\bar{\eta}/l) d\bar{\eta}, \quad (4.3.2)$$

где G – пространство решений,

$\sigma(\gamma_k / \bar{\eta})$ – правило решения,

$\bar{\eta}$ – вектор принимаемых данных,

$P(\bar{\eta}/l)$ – плотность распределения принимаемых данных при условии, что истинна гипотеза «1».

Производя замену переменных и выбирая в качестве новой переменной функцию

$$y_k = l(k), \quad (4.3.3)$$

приходим к выражению для вероятности ошибки в виде многомерного интеграла от совместного распределения статистик $y_1 \dots y_N$

по той области пространства решений, которая соответствует k -й гипотезе:

$$P(k/l) = \int_{G_k} \dots \int W^{(l)}(y_1 \dots y_M) dy_1 \dots dy_M, \quad (4.3.4)$$

где $W^{(l)}(\bar{y})$ – совместная плотность распределения случайных величин $y_1 \dots y_M$ при условии, что принимается 1-я гипотеза;

M – общее число принимаемых гипотез;

G_k – область пространства решений, соответствующая принятию k -й гипотезы.

В рассматриваемом случае пределы интегрирования в выражении для вероятности принятия решения о наличии цели k -го класса при наблюдении цели 1-го класса могут быть конкретизированы:

$$P(k/l) = \int_{-\infty}^{\infty} dy_k \int_{-\infty}^{y_k} \dots \int_{-\infty}^{y_k} W^{(l)}(y_1 \dots y_N) dy_1 \dots dy_N. \quad (4.3.5)$$

Плотность распределения $W^{(l)}(\bar{y})$ выражается через значения отсчетов РЛИ с помощью формулы:

$$W^{(l)}(\bar{y}) = \int_{\Gamma} P(\bar{\eta}/l) \prod_{\alpha=1}^M \sigma(y_{\alpha} - Y(\alpha)) d\bar{\eta}. \quad (4.3.6)$$

С учетом независимости компонент вектора наблюдений $\bar{\eta}$ плотность вероятности $P(\bar{\eta}/l)$ имеет вид:

$$P(\bar{\eta}/l) = \prod_{i=1}^N \frac{1}{\xi_i^{(l)}} \exp\left(-\frac{\eta_i}{\xi_i^{(l)}}\right), \quad (4.3.7)$$

где N – размерность вектора наблюдений $\bar{\eta}$.

Определим σ – функцию, входящую в (4.3.5), следующим образом:

$$\delta(y_{\alpha} - Y(\alpha)) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \exp\{-jz_{\alpha} [y_{\alpha} - Y(\alpha)]\} dz_{\alpha}.$$

Подставляя (4.3.2) в (4.3.7) и (4.3.6) в (4.3.5), получим:

$$W^{(l)}(\bar{y}) = \int_{\bar{A}} \left\{ \prod_{i=1}^N \frac{1}{\xi_i^{(l)}} e^{\frac{\eta_i}{\xi_i^{(l)}}} \right\} \times \left\{ \frac{1}{(2\pi)^N} \prod_{\alpha=1}^M \int_{-\infty}^{\infty} \exp[-jz_{\alpha}(y_{\alpha} + \right. \\ \left. + \sum_{i=1}^N \frac{\eta_i}{\xi_i^{(\alpha)}} + \sum_{i=1}^N \ln \xi_i^{(\alpha)}] dz_{\alpha} \right\} d\eta_1 \dots d\eta_N. \quad (4.3.8)$$

После замены переменных:

$$x_{\alpha} = y_{\alpha} + \sum_{i=1}^N \ln \xi_i^{(\alpha)} \quad (4.3.9)$$

определим характеристическую функцию, соответствующую плотности распределения

$$F(z_1, \dots, z_N) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \exp \left[j \sum_{i=1}^M z_i y_i \right] W^{(l)}(y_1 \dots y_M) dy_1 \dots dy_M = \\ = \prod_{i=1}^N \frac{1}{1 + j \sum_{\alpha=1}^M \frac{\xi_i^{(l)}}{\xi_i^{(\alpha)}} z_{\alpha}}. \quad (4.3.10)$$

Для определения плотности вероятности $W^{(l)}(\bar{x})$ найдем обратное преобразование Фурье от последнего выражения (4.3.10):

$$W^{(l)}(\bar{x}) = \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \exp \left[-j \sum_{\alpha=1}^M z_{\alpha} x_{\alpha} \right] F(z_1 \dots z_M) dz_1 \dots dz_M = \\ = \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left\{ \prod_{i=1}^N \frac{1}{1 + j \sum_{\alpha=1}^M \frac{\xi_i^{(l)}}{\xi_i^{(\alpha)}} z_{\alpha}} \right\} e^{-j \sum_{\alpha=1}^M z_{\alpha} x_{\alpha}} dz_1 \dots dz_M \quad (4.3.11)$$

Вычисление полученного интеграла приводит к чрезвычайно громоздким результатам. И тем не менее эти вычисления следовало бы

привести при том условии, что полученные выражения носили бы конструктивный характер, а именно позволяли бы рассчитать вероятности ошибочных решений.

Поэтому рассмотрим вначале частный случай, при котором вычисление (4.3.11) тривиально и убедимся в степени продуктивности полученного решения для анализа эффективности распознавания в целом.

Допустим, что размерность вектора наблюдений, равная N , совпадает с числом конкурирующих гипотез M . На практике обычно выполняется неравенство $N > M$. Тем не менее, такое предположение не лишено целесообразности. Оно приводит к расширению числа классов ПРЦ – появлению подклассов в пределах каждого класса, что делает задачу анализа эффективности классификации более детальной. После расчета вероятностей ошибок, если, разумеется, такой расчет удастся осуществить аналитическими методами, результаты можно «заглубить», объединяя вероятности ошибочных решений внутри подкласса.

После замены переменных:

$$p = \sum_{\alpha=1}^M \frac{\xi_i^{(\alpha)}}{\xi_i^{(\alpha)}} z_{\alpha} \quad (4.3.12)$$

или в матричной записи:

$$Q^{(l)} \bar{Z} = \bar{P},$$

где

$$Q^{(l)} = \|q_{ij}^{(l)}\| = \left\| \frac{\xi_i^{(l)}}{\xi_j^{(j)}} \right\| \quad (4.3.13)$$

и предположения о том, что матрица Q – неособенная, перепишем формулу (3.3.11):

$$\begin{aligned} W^{(l)}(\bar{x}) &= \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int \left\{ \prod_{i=1}^N \frac{1}{1 + jp_i} \right\} \frac{1}{|Q^{(l)}|} e^{-j \left[Q^{(l)\top} \bar{P} \right]} d\bar{P} = \\ &= \frac{1}{|Q^{(l)}|} \prod_{i=1}^N \int_{-\infty}^{\infty} \frac{1}{2\pi} \frac{1}{1 + jp_i} e^{-jp_i \gamma_i} dp_i. \end{aligned} \quad (4.3.14)$$

В последнем выражении приняты следующие обозначения:

$$\gamma_i = \sum_{l=1}^M x_i c_{il}, \quad (4.3.15)$$

где, в свою очередь, c_{il} – элемент матрицы:

$$C = \left(Q^{(l)^{-1}} \right). \quad (4.3.16)$$

Интегралы, стоящие в (4.3.14), легко вычисляются, и выражение для плотности вероятности принимает вид:

$$W^{(l)}(x) = \begin{cases} \frac{1}{|Q^{(l)}|} e^{\sum_j x_j c_{jj}} & \text{если } \sum_i x_i c_{ji} < 0 \text{ для каждого } j = \overline{1, M}; \\ 0 & \text{если } \sum_i x_i c_{ji} > 0 \text{ для каждого } j = \overline{1, M}. \end{cases} \quad (4.3.17)$$

Подставив (4.3.17) в выражение (4.3.5), получим формулу для расчета вероятностей ошибок:

$$P(k/l) = \int dx \int_{x_k + \sum \ln(\xi_i^{(l)}/\xi_i^{(k)})} \dots \int_{x_k + \sum \ln(\xi_i^{(N)}/\xi_i^{(k)})} \times \frac{1}{|Q^{(l)}|} e^{\sum x_i \sum c_{ij}} dx_1 \dots dx_n, \quad (4.3.18)$$

при условии $\sum_{i=1}^N x_i c_j < 0$ для каждого $j = \overline{1, M}$.

Вычисление последнего интеграла аналитическими методами представляет собой непреодолимую задачу. Общий случай ($M \neq N$) еще более сложен.

4.3.2. Вывод расчетных выражений для оценки вероятностей правильных и ошибочных решений при классификации ПРЦ по РЛИ

Рассмотрим приближенный метод [7] определения вероятностей правильных и ошибочных выборов гипотез о классах ПРЦ. Алгоритм проверки гипотез принимает решение об истинности класса ПРЦ, если соответствующее ему значение статистики:

$$l(k) = -\sum_{i=1}^N \left(\frac{\eta_i}{\xi_i^{(k)}} + \ln \xi_i^{(k)} \right), \quad (4.3.19)$$

основанной на модели плотности вероятности наблюдаемого вектора (3.3.7), принимает максимальное значение.

Для выходной статистики, построенной в предположении, что ПРЦ соответствует k -му классу при условии, что на самом деле вектор наблюдаемых данных $\vec{\eta}$ соответствует 1-му классу, введем обозначение $l^{(1)}(k)$.

Ошибка классификации имеет место в том случае, когда при наблюдении РЛИ ПРЦ 1-го класса выносится решение в пользу ПРЦ k -го класса. Такая ситуация наступает, если выходной эффект, соответствующий k -й гипотезе $l^{(1)}()$, оказывается больше, чем выходной эффект, соответствующий истинной гипотезе 1:

$$l^{(1)}(k) > l^{(1)}(1). \quad (4.3.20)$$

Вероятность этого события определяется выражением:

$$\begin{aligned} P[l^{(1)}(k) > l^{(1)}(1)] &= P[l^{(1)}(k) - l^{(1)}(1) > 0] = \\ &= P\left[\sum_{i=1}^m \left(\frac{11}{\xi^{(1)}} - \frac{1}{\xi^{(k)}} \right) \eta_i > \sum_{i=1}^m \ln \frac{\xi_i^{(k)}}{\xi_i^{(1)}}\right]. \end{aligned} \quad (4.3.21)$$

В общем случае формула для вероятности правильного решения может быть записана следующим образом:

$$P(l/l) = 1 - P\left[\begin{matrix} l^{(l)}(k) > l^{(l)}(l) \\ k \neq l \end{matrix} \text{ для любых } k = \overline{1, m} \right]. \quad (4.3.22)$$

Поскольку выходной эффект $l^{(l)}(k)$ может превышать статистику $l^{(l)}(l)$ при нескольких значениях k (события совместны), точный расчет вероятностей в правой части (3.3.22) довольно сложен (формально эта процедура не отличается от описанной в предыдущем параграфе). Однако, используя только вероятности (3.3.21), удастся записать выражение для нижней границы вероятности правильного решения:

$$P(l/l) \geq 1 - \sum_{\substack{k=1 \\ k \neq l}}^M P[l^{(l)}(k) > l^{(l)}(l)] . \quad (4.3.23)$$

Следует иметь в виду, что с повышением точности классификации нижняя граница вероятности правильного решения (4.3.23) приближается к истинному значению вероятности. Действительно, чем выше эффективность устройства классификации, тем меньше вероятность события, заключающегося в том, что выходные эффекты, соответствующие двум и более ложным гипотезам, будут превышать статистику (4.3.19), соответствующую наблюдению истинной цели. Приведенное заключение имеет тем больше оснований, чем меньше число конкурирующих гипотез, что соответствует рассматриваемой ситуации классификации ПРИ.

Введем обозначения:

$$u = \sum_{i=1}^N \left(\frac{1}{\xi_i^{(l)}} - \frac{1}{\xi_i^{(k)}} \right) \eta_i ; \quad (4.3.24)$$

$$Q = \sum_{i=1}^N \ln \frac{\xi_i^{(k)}}{\xi_i^{(l)}} , \quad (4.3.25)$$

причем $\xi_i^{(l)} \neq \xi_i^{(k)}$ (в противном случае отсчеты конкурирующих РЛИ не отличаются и соответствующие значения ЭПР исключаются из рассмотрения),

$$p_l^k = P[l^{(l)}(k) > l^{(l)}(l)] , \quad (4.3.26)$$

где
$$p_l^k = P\left(\frac{k}{l}\right) = \int_Q^\infty W\left(\frac{u}{l}\right) du . \quad (4.3.27)$$

В (4.3.27) функция $W(u/l)$ представляет собой плотность распределения вероятностей случайной величины u , определенной из (4.3.24), при

условии, что случайные величины η_i , как это следует из исходной постановки задачи, имеют плотность распределения вероятностей:

$$W(\eta) = \frac{1}{\xi_i^{(l)}} e^{-\frac{\eta_i}{\xi_i^{(l)}}}. \quad (4.3.28)$$

Характеристическая функция, соответствующая распределению (3.3.28), имеет вид:

$$\theta_{\eta_i}(V) = \frac{1}{1 - jV\xi_i^{(l)}}. \quad (4.3.29)$$

Обозначив

$$g = \frac{1}{\xi_i^{(l)}} - \frac{1}{\xi_i^{(k)}}, \quad (4.3.30)$$

найдем характеристическую функцию величины $g_i \eta_i$:

$$\theta_{g\eta} = \frac{1}{1 - jvg_i\xi_i^{(l)}}. \quad (4.3.31)$$

Характеристическая функция для u определяется как характеристическая функция суммы независимых случайных величин:

$$\theta_u(V) = \prod_{i=1}^N \frac{1}{1 - jvg_i\xi_i^{(l)}}. \quad (4.3.32)$$

Преобразовав (3.3.32) по Фурье, находим плотность вероятности:

$$W\left(\frac{u}{l}\right) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left(\prod_{i=1}^N \frac{1}{1 - jv\xi_i^{(l)}g_i} \right) e^{-jvu} dv. \quad (4.3.33)$$

Обозначим

$$\xi_i = \frac{1}{\xi_i^{(l)}g_i} \quad (4.3.34)$$

и перепишем выражение (3.3.33):

$$W(u/l) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left(\prod_{i=1}^N \frac{\xi_j}{\xi_i - jv} \right) e^{-jvu} dv. \quad (4.3.35)$$

Для вычисления полученного интеграла (4.3.35) рассмотрим типовые практически важные ситуации и примем ряд предположений. Будем считать, что каждое из распознаваемых РЛИ: 1-е и k -е в общем случае содержат $m_b^{(j)}$ ($j = 1, M$) отсчетов, вызванных наличием «блестящих» точек, $m_{\Pi}^{(j)}$ ($j = 1, M$) отсчетов, определяющихся диффузионными отражениями от распределённой поверхности ПРЦ и $m_M^{(j)}$ ($j = 1, M$) отсчетов от подстилающей поверхности. Отсчеты от «блестящих» точек на каждом из РЛИ отличаются по величине ЭПР как между собой, так и между отсчетами от «блестящих» точек, распределённой и подстилающей поверхности на «своем» и конкурирующем РЛИ. Иначе ведут себя отсчеты, соответствующие распределённой поверхности: в пределах «своего» РЛИ они не отличаются по величине ЭПР и, следовательно, отличаются от отсчетов распределённой поверхности другого РЛИ на постоянную величину. Относительно подстилающей поверхности могут быть высказаны аналогичные соображения. Из сказанного следует, что при наличии $m_{\text{кп}}$ отсчетов распределённой поверхности на одинаковых позициях двух РЛИ такова же кратность полюсов подынтегрального выражения. Если число элементов двух РЛИ, имеющих одинаковые расположения и «занятых» МП, равно $m_{\text{км}}$, то в подынтегральном выражении столько же одинаковых полюсов, разумеется, отличающихся по значению от «полюсов подстилающей поверхности».

При выполнении принятых предположений вычислим интеграл (4.3.35):

$$\begin{aligned}
 W(u/l) = & \sum_{q \in M_b} \xi_q e^{-\xi_q u} \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(\xi_q) + \\
 & + \left\{ \frac{1}{(m_{\text{кп}} - 1)!} \lim_{p \rightarrow \xi_{\Pi}} \frac{d^{m_{\text{кп}} - 1}}{dp^{m_{\text{кп}} - 1}} \left[e^{-pu} \frac{\xi_{\Pi}^{m_{\text{кп}}} \xi_M^{m_{\text{кп}}}}{(\xi_M - p)^{m_{\text{кп}}}} \prod_{i \in M_b} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_{\Pi}) + \\
 & + \left\{ \frac{1}{(m_{\text{км}} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{\text{км}} - 1}}{dp^{m_{\text{км}} - 1}} \left[e^{-pu} \frac{\xi_{\Pi}^{m_{\text{кп}}} \xi_M^{m_{\text{км}}}}{(\xi_{\Pi} - p)^{m_{\text{км}}}} \prod_{i \in M_b} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_M)
 \end{aligned} \quad (4.3.36)$$

при $u > 0$

$$\text{где } l(x) = \begin{cases} 1 & x > 0; \\ 0 & x < 0. \end{cases}$$

В выражении (4.3.36) суммирование производится лишь по тем индексам, для которых $\zeta_q > 0$ ($q \in M_B$, причем M_B – множество тех позиций 1-го и k -го РЛИ, на которых расположены «блестящие точки», другими словами, множество некратных полюсов).

При $u < 0$ интеграл (3.3.35) выглядит аналогично.

$$\begin{aligned}
 W(u/l) = & \sum_{q \in M_B} \xi_q e^{-\xi_q u} \prod_{\substack{i \in M_B \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(-\xi_q) + \\
 & + \left\{ \frac{1}{(m_{k\Pi} - 1)!} \lim_{p \rightarrow \xi_\Pi} \frac{d^{m_{k\Pi} - 1}}{dp^{m_{k\Pi} - 1}} \left[e^{-pu} \frac{\xi_\Pi^{m_{k\Pi}} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_\Pi) + \\
 & + \left\{ \frac{1}{(m_{kM} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{kM} - 1}}{dp^{m_{kM} - 1}} \left[e^{-pu} \frac{\xi_\Pi^{m_{k\Pi}} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_M).
 \end{aligned} \quad (4.3.37)$$

В последнем выражении суммирование производится лишь по тем индексам, для которых $\zeta_i < 0$.

После подстановки (4.3.36) и (4.3.37) в (4.3.27) найдем формулу для вычисления вероятности превышения ложным выходным эффектом истинного.

а) при $Q > 0$:

$$\begin{aligned}
 p_l^k = & \sum_{q \in M_B} e^{-\xi_q Q} \prod_{\substack{i \in M_B \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(\xi_q) + \\
 & + \left\{ \frac{1}{(m_{k\Pi} - 1)!} \lim_{p \rightarrow \xi_\Pi} \frac{d^{m_{k\Pi} - 1}}{dp^{m_{k\Pi} - 1}} \left[e^{-\xi_\Pi Q} \frac{\xi_\Pi^{m_{k\Pi}} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_\Pi) + \\
 & + \left\{ \frac{1}{(m_{kM} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{kM} - 1}}{dp^{m_{kM} - 1}} \left[e^{-\xi_M Q} \frac{\xi_\Pi^{m_{k\Pi}} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_M),
 \end{aligned} \quad (4.3.38)$$

где r – номера тех индексов, для которых $\zeta_q > 0$.

б) при $Q < 0$:

$$\begin{aligned}
 p_l^k = & \sum_{q \in M_B} (1 - e^{-\xi_q Q}) \prod_{\substack{i \in M_B \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(-\xi_q) + \sum_{r \in M_B} \prod_{\substack{i \in M \\ i \neq r}} \frac{\xi_i}{\xi_i - \xi_r} l(\xi_r) + \\
 & + \left\{ \frac{1}{(m_{k\Pi} - 1)!} \lim_{p \rightarrow \xi_{\Pi}} \frac{d^{m_{k\Pi}-1}}{dp^{m_{k\Pi}-1}} \left[(1 - e^{-\xi_{\Pi} Q}) \frac{\xi_{\Pi}^{m_{k\Pi}-1} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_{\Pi}) + \\
 & + \left\{ \frac{1}{(m_{kM} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{kM}-1}}{dp^{m_{kM}-1}} \left[(1 - e^{-\xi_M Q}) \frac{\xi_{\Pi}^{m_{k\Pi}} \xi_M^{m_{kM}-1}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_B} \left(\frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_M).
 \end{aligned} \quad (4.3.39)$$

Вычисления по приведенным формулам неоправданно громоздки и могут быть существенно упрощены в соответствии со следующими предположениями:

а) размер фрагмента РЛИ выбирается таким образом, чтобы не превышать максимальных размеров РЛИ ПРЦ, что заведомо ограничивает возможное число отсчетов, приходящихся на подстилающую поверхность;

б) отношение сигнал/фон в каждом элементе разрешения, содержащем отсчеты, принадлежащие цели, для реальных РЛИ составляет не менее 10 дБ;

в) в «блестящих» точках РЛИ ПРЦ сосредоточено, по крайней мере, 80 % ее ЭПР.

При этом расчетная формула для определения вероятности правильной классификации ПРЦ k -го класса выглядит следующим образом:

$$p(l/l) \geq 1 - \sum_{\substack{k=1 \\ k \neq l}}^M \sum_{q \in M_B} e^{-\xi_q^{lk} Q} \prod_{\substack{i \in M_B \\ i \neq q}} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(\xi_q^{lk})$$

при $Q > 0$.

$$p(l/l) \geq 1 - \sum_{k=1}^M \left\{ \sum_{q \in M_b} (1 - e^{-\xi_q^{lk} Q}) \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(-\xi_q^{lk}) + \right. \\ \left. + \sum_{q \in M_b} \prod_{i \in M_b} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(\xi_q^{lk}) \right\} \quad (4.3.40)$$

при $Q < 0$.

В выражении (3.3.40) приняты следующие обозначения:

$$\xi_i^{lk} = 1 - \frac{\xi_i^l}{\xi_i^k};$$

$$Q = \sum_{i=1}^N \ln \frac{\xi_i^k}{\xi_i^l}.$$

Предположим, что РЛИ ПРЦ k -го класса представляет собой совокупность n_k экспоненциально распределенных независимых отсчетов, принадлежащих цели, и, соответственно, $m - n_k$ отсчетов, созданных только шумом, причем, «целевые» отсчеты имеют одинаковую между собой ЭПР, равную σ_k/n_k (σ_k – интегральная ЭПР цели k -го класса, а параметр экспоненциального распределения «шумовых» отсчетов равен $\sigma_{ш}$).

В этом случае оптимальный алгоритм классификации может быть синтезирован по критерию максимального правдоподобия, в соответствии с которым решения принимается в пользу той гипотезы, для которой отношение правдоподобия максимально:

$$\hat{k} = \operatorname{argmax} \Delta(n_k, \sigma_k) = \operatorname{argmax} \frac{W(\bar{\eta}/n_k, \sigma_k)}{W(\bar{\eta}/\text{шум})}. \quad (4.3.41)$$

где $W(\bar{\eta}/n_k, \sigma_k)$ – плотность вероятности вектора наблюдаемых данных $\bar{\eta}$ при наличии цели k -го класса;

$W(\bar{\eta}/\text{шум})$ – плотность вероятности вектора наблюдаемых данных $\bar{\eta}$ при наличии только шума.

При экспоненциальном распределении вероятностей отсчетов РЛИ отношение правдоподобия может быть записано в следующем виде:

$$\Delta(n, \sigma) = \frac{1}{\left(1 + \frac{\sigma_k}{\sigma_{\text{ш}} n_k}\right)^{n_k}} \exp \left\{ \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}} \sum_{n_k} x_i \right\}, \quad (4.3.42)$$

где $x_i = \frac{\eta_i}{\sigma_{\text{ш}}}$.

Вероятность принятия k -й гипотезы при истинной гипотезе с номером l находится из условия:

$$P\{I(k) > I(l)\} = P \left\{ \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}} \sum_{n_k} x_i - \frac{\frac{\sigma_l}{n_l \sigma_{\text{ш}}}}{1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}} \sum_{n_l} x_i > \ln \frac{\left(1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}\right)^{n_k}}{\left(1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}\right)^{n_l}} \right\}. \quad (4.3.43)$$

В рассматриваемой ситуации гипотезы могут быть упорядочены следующим образом: с возрастанием номера гипотезы как размеры ПРЦ, так и ее интегральная ЭПР уменьшаются, то есть при $K > 1$ считаем, что $n_k < n_l$ и наоборот. Введем обозначения:

$$\beta_k = \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}}$$

при $k > l$ ($n_l > n_k$),

$$y = (\beta_k - \beta_l) \sum_{n_k} x_i - \beta_l \sum_{n_l - n_k} x_i; \quad (4.3.44)$$

при $k < l$ ($n_k > n_l$),

$$y = (\beta_k - \beta_l) \sum_{n_l} x_i + \beta_k \sum_{n_k - n_l} x_i.$$

Поскольку справедливой считается 1-я гипотеза, в случае «а» плотность вероятности случайной величины x_i равна

$$W(x_i) = \frac{1}{1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}} \exp \left(-\frac{x_i}{1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}} \right) \text{ при } x_i > 0 \quad (4.3.45)$$

в первой и второй суммах, а в случае «б» плотность вероятности в первой сумме определяется в соответствии с выражением (4.3.45), а во второй сумме:

$$W(x_i) = \exp(-x_i).$$

После определения характеристической функции и плотности вероятности случайной величины y найдем расчетные выражения для вероятностей ошибочных и верных решений относительно принятия k -й гипотезы при истинной гипотезе с номером 1.

При $k > 1; \xi_1^{kl} > 0; Q > 0$:

$$p_l^k = \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{1}{\xi_2^l}} \frac{d^{n_l - n_k - i}}{dp^{n_l - n_k - l}} \left\{ \frac{(-1)e^{pQ}}{p(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k - 1} \left(p \frac{1}{\xi_1^{kl}} \right)} \right\}.$$

При $k > 1; \xi_1^{kl} > 0; Q < 0$:

$$\begin{aligned} p_l^k = & \frac{1}{(n_k - 1)!} \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \lim_{p \rightarrow \frac{1}{\xi_1^{kl}}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left\{ \frac{1 - e^{pQ}}{\left(p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right\} + \\ & + \frac{1}{(n_l - n_k - 1)!} \frac{(-1)^k}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left\{ \frac{1}{\left(p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right\}. \end{aligned}$$

При $k > 1$; $\xi_1^{kl} < 0$; $Q > 0$:

$$p_l^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{-1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[\frac{e^{pQ}}{p \left(p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right] \right\} +$$

$$+ \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[\frac{e^{pQ}}{p \left(p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right].$$

При $k > 1$; $\xi_1^{kl} < 0$; $Q < 0$:

Результат – предыдущая формула при $Q = 0$.

При $k < 1$; $\xi_1^{kl} > 0$; $Q > 0$:

$$p_l^k = 0.$$

При $k < 1$; $\xi_1^{kl} > 0$; $Q < 0$:

$$p_l^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_l} (\xi_3^k)^{n_k - n_l}} \left\{ \frac{1}{(n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_1^{kl}}} \frac{d^{n_l - 1}}{dp^{n_l - 1}} \left[\frac{1 - e^{pQ}}{p \left(p - \frac{1}{\xi_3^k} \right)^{n_k - n_l}} \right] \right\} +$$

$$+ \frac{1}{(n_k - n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_3^k}} \frac{d^{n_k - n_l - 1}}{dp^{n_k - n_l - 1}} \left[\frac{1 - e^{pQ}}{p \left(p - \frac{1}{\xi_1^{kl}} \right)^{n_l}} \right].$$

При $k < 1$; $\xi_1^{kl} < 0$; $Q > 0$:

$$p_l^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[\frac{-e^{pQ}}{p \left(p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right] + \right. \\ \left. + \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[\frac{-e^{pQ}}{p \left(p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right] \right\}.$$

При $k < 1$; $\xi_1^{kl} < 0$; $Q < 0$:

$$p_l^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_l} (\xi_3^k)^{n_k - n_l}} \left\{ \frac{1}{(n_k - n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_3^k}} \frac{d^{n_k - n_l - 1}}{dp^{n_k - n_l - 1}} \left[\frac{1 - e^{pQ}}{p \left(p - \frac{1}{\xi_1^{kl}} \right)^{n_l}} \right] + \right. \\ \left. + \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[\frac{1}{p \left(p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right] + \right. \right. \\ \left. \left. + \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[\frac{1}{p \left(p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right] \right\} \right\}. \quad (4.3.46)$$

При записи выражения (4.3.46) использованы следующие обозначения:

$$\xi_1^{kl} = \frac{1}{1 + \frac{\sigma_l}{n_l \sigma_{\text{III}}}} \frac{1}{\beta_k - \beta_l};$$

$$\xi_2^l = \left(\frac{\sigma_l}{n_l \sigma_{\text{III}}} \right)^{-1};$$

$$\sigma_3^k = (\beta_k)^{-1}.$$

Существенного упрощения вычислений можно достичь при условии, что количество слагаемых в первой и второй суммах выражения (4.3.44) достаточно велико, чтобы считать справедливым предположение о нормализации случайной величины y . В этом случае статистика (4.3.44) гауссова и имеет следующие параметры.

При $k > 1$

$$M\{y\} = \left(1 + \frac{\sigma_l}{n_l \sigma_{\text{III}}} \right) (\beta_k n_k - \beta_l n_l);$$

$$D\{y\} = \left(1 + \frac{\sigma_l}{n_l \sigma_{\text{III}}} \right)^2 (n_k \beta_k^2 - 2n_k \beta_k \beta_l + n_l \beta_l^2).$$

При $k < 1$

$$M\{y\} = (\beta_k - \beta_l) n_l \left(1 + \frac{\sigma_l}{n_l \sigma_{\text{III}}} \right) + \beta_k (n_l - k_k);$$

$$D\{y\} = \left(1 + \frac{\sigma_l}{n_l \sigma_{\text{III}}} \right)^2 (\beta_k - \beta_l)^2 n_k + \beta_k^2 (n_k - n_l).$$

Оценки вероятностей ошибочных и верных решений находится из очевидного соотношения:

$$p_l^k = 1 - \Phi \left\{ \frac{Q - M}{D^{1/2}} \right\}$$

4.3.3. Оценка эффективности классификации при корнях большой кратности

Методологическая основа расчета информативности та же, что и в разделе 4.1.

Для расчета вероятности p_l^k воспользуемся предположением, о том, что компоненты (квадратурные составляющие на выходе линейной части устройства формирования РЛИ), образующие в результате вектор отсчетов радиолокационного портрета $\bar{\eta}$, статистически независимы и нормальны. В этом случае решение принимается в соответствии с алгоритмом (4.3.1) а вероятности p_l^k находятся в соответствии со следующим приближенным выражением:

$$p_l^k = \exp \{ \mu_l^k(S) - S \dot{\mu}_l^k(S) \}, \quad (4.3.47)$$

где

$$\begin{aligned} \mu_l^k(S) &= \ln \int \dots \int P^S(\bar{\eta}/k) P^{1-S}(\bar{\eta}/l) d\bar{\eta} = \\ &= \frac{1}{2} \sum_{i=1}^N \left\{ \frac{S(S-1)(m_{ki} - m_{li})^2}{S\sigma_{li}^2 + (1-S)\sigma_{ki}^2} \ln \frac{(\sigma_{ki}^2)^{1-S} (\sigma_{li}^2)^S}{S\sigma_{li}^2 + (1-S)\sigma_{ki}^2} \right\}, \end{aligned} \quad (4.3.48)$$

причем S выбирается из условия $\mu_l^k(S) = 0$.

В последнем выражении: m_{ki} – математическое ожидание, а σ_{ki}^2 – дисперсия i -й компоненты признака при наблюдении ПРЦ k -го класса. Для случая, аналогичного анализу алгоритма (4.3.1):

$$m_{ki} = 0 \quad (k = 1, M; \quad i = 1, N); \quad \sigma_{ki}^2 = \xi_i^k. \quad (4.3.49)$$

4.4. Анализ алгоритмов классификации по РЛИ ПРЦ

Расчет по формулам (4.3.38)–(4.3.39) для трех упомянутых типов ПРЦ позволяет получить следующую матрицу вероятностей правильных и ошибочных решений:

$$P = \begin{pmatrix} P(1/1) & P(2/1) & P(3/1) \\ P(1/2) & P(2/2) & P(3/2) \\ P(1/3) & P(2/3) & P(3/3) \end{pmatrix} = \begin{pmatrix} 0,977 & 0,021 & 0,002 \\ 0,013 & 0,964 & 0,023 \\ 0,010 & 0,038 & 0,952 \end{pmatrix}, \quad (4.4.1)$$

где $P(1/k)$ – вероятность принятия решения в пользу 1-го класса при истинном – k . Номера соответствуют: 1 – «большая» цель, 2 – цель «среднего» класса и 3 – «малая» цель.


Результаты приведены для случая, когда какие-либо искажения радиолокационных портретов отсутствуют, а удельная ЭПР подстилающей поверхности (–30 дБ) настолько мала, что ее величина практически не оказывает влияния на качество классификации.

Для анализа алгоритмов классификации в более широком спектре условий наблюдения, по-видимому, нет альтернативы методам статистического моделирования. В данном разделе приведены результаты такого моделирования для анализа эффективности классификации трех типов ПРЦ при двух вариантах разрешающей способности (12 м и 24 м), трех значениях удельной ЭПР МП (–30, –20 и –10 дБ), и трех ракурсах наблюдения ПРЦ (0°, 45° и 90°). Примеры РЛИ показаны на рис. 4.10, а матрицы вероятностей – в табл. 4.1.


4.5. Распознавание ПРЦ по данным разных средств наблюдения

В тех случаях, когда по одному вектору наблюдаемых данных требуемая вероятность правильной классификации обеспечена быть не может, встает вопрос об оптимальном использовании совокупности всех данных для принятия решения о классе ПРЦ: разработке соответствующих алгоритмов и анализе их эффективности.

Один из наиболее простых и эффективных путей повышения качества распознающих систем заключается в коллективном принятии решения путём объединения выводов (голосов), принятых отдельными автоматами, возможно, разной физической природы, например: оптическими, тепловыми, телевизионными, радиолокационными и т. п. Другими словами, итоговое решение принимается коллективом решающих правил, между которыми устраивается голосование.



ЭПР МП = -30дБ



ЭПР МП = -10дБ

Рис. 4.10. Примеры РЛИ ПРЦ

Таблица 4.1

Матрицы вероятностей правильных решений

№ п/п	Разрешение (м)	ЭПР МП (дБ)	Ракурс	P
1	2	3	4	5
1	12	-30	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$
			45°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
2	12	-20	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,05 & 0,95 \end{pmatrix}$
			45°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,9 & 0,1 & 0 \\ 0 & 1 & 0 \\ 0 & 0,15 & 0,85 \end{pmatrix}$
3	12	-10	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$
			45°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,2 & 0,8 & 0 \\ 0 & 0,35 & 0,65 \\ 0 & 0,2 & 0,8 \end{pmatrix}$

Окончание табл. 4.1

1	2	3	4	5
4	24	-30	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,7 & 0,3 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			45°	$\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0,1 & 0,85 & 0,05 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 0,85 & 0,15 \\ 0 & 0,2 & 0,8 \end{pmatrix}$
5	24	-20	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,6 & 0,4 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			45°	$\begin{pmatrix} 0,7 & 0,3 & 0 \\ 0,1 & 0,85 & 0,05 \\ 0 & 0,05 & 0,95 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 0,8 & 0,2 \\ 0 & 0,3 & 0,7 \end{pmatrix}$
6	24	-10	0°	$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,3 & 0,7 \\ 0 & 0,1 & 0,9 \end{pmatrix}$
			45°	$\begin{pmatrix} 0,9 & 0,1 & 0 \\ 0,1 & 0,8 & 0,1 \\ 0,05 & 0,3 & 0,65 \end{pmatrix}$
			90°	$\begin{pmatrix} 0,1 & 0,2 & 0,65 \\ 0 & 0,1 & 0,9 \\ 0 & 0,1 & 0,9 \end{pmatrix}$

4.5.1. Коллективное распознавание

Коллективом, принимающим решения, считаем совокупность автоматов R_p (L – число автоматов, принимающих решения), каждый из которых принимает индивидуальное решение S_p . В этом случае коллективное решение представляет собой некоторую функцию индивидуальных решений:

$$S = F(S_1, S_2, \dots, S_L; X), \quad (4.5.1)$$

где F – алгоритм принятия коллективного решения,
 $X = (x_1, x_2, \dots, x_n)$ – вектор параметров (признаков) классифицируемых объектов.

Структурная схема алгоритма коллективного принятия решения приведена на рис. 4.11.




Рис. 4.11. Алгоритм коллективного принятия решения

Решение S заключается в выборе номера j одного из возможных классифицируемых объектов для вектора наблюдаемых данных X .

Рассмотрим алгоритм голосования. Пусть q_j – голосующая функция j -го класса:

$$q_j = \sum_l \mu_l, \quad (4.5.2)$$

где μ_l – нормированный вес l -го решающего правила. Суммирование ведётся по тем l , для которых $S_l = j$.

Решение о принадлежности вектора X к классу A_j принимается по следующему правилу:

$$X \in A_{j^*}, \quad \text{если } q_{j^*} = \max_j q_j. \quad (4.5.3)$$

Алгоритм коллективного принятия решения может строиться на основе двух принципов: объединение признаков; объединение решений.

В первом случае от L различных средств наблюдения (СН) в центральный пункт (ЦП) обработки поступают значения признаков, например, данные радиолокационной разведки (РЛР) – отсчеты РЛИ или функции от них; данные радиотехнической разведки (РТР) – параметры разведанных сигналов – мощность, частота, длительность импульсов, период их следования и т.д.; данные радиоразведки (РР) – вид и глубина модуляции РР. При достаточных временных и вычислительных ресурсах традиционное классическое решение задачи классификации обеспечивает достоверность, близкую к оптимальной. В то же время названный подход является чрезвычайно громоздким.

В этом случае целесообразно комплексирование информации на уровне объединения решений, вынесенных отдельными средствами наблюдения, например с использованием правила (3)

Близким к оптимальному будет применение правила взвешенного суммирования [2], содержание которого заключается в следующем. При поступлении в ЦП решения 1-го источника информации ($l = \overline{1, L}$) в пользу i -го класса для каждого j -го класса ($i, j = \overline{1, M}$) вычисляется коэффициент, равный:

$$V_{jl} = C_{ijl}; \quad C_{ijl} = A \lg \frac{P_{ijl}}{P_{il}}, \quad (4.5.4)$$

$$\text{где } P_{il} = \min_j P_{ijl}; \quad A^{-1} = \max_{i,j,l} \lg \left(\frac{P_{ijl}}{P_{il}} \right),$$

а P_{ijl} – вероятность вынесения решения в пользу i -го класса 1-м источником при фактическом наличии ПРЦ j -го класса. Полученные коэффициенты суммируются

$$V_j = \sum_{l=1}^L V_{jl}; \quad j = \overline{1, M}$$

и принимается решение в пользу класса, для которого величина V_j максимальна.

Рассмотрим некоторые упрощения алгоритма взвешенного суммирования. Прежде всего проанализируем ситуацию, когда вероятности правильных и ошибочных решений одинаковы для разных СН:

$$P_{ji1} = P_{ji2} = \dots = P_{jiL} = P_0;$$

$$P_{ij1} = P_{ij2} = \dots = P_{ijL} = \frac{1 - P_0}{M - 1}; \quad 1 \neq j; \quad 1, j = \overline{1, M}.$$

В этом случае реализуется процедура «простого голосования», когда решение принимается в пользу того класса, за который «голосует» большинство СН. Названная процедура является оптимальной, если:

- источники информации статистически независимы;
- достоверность источников одинакова;
- вероятности ошибочных решений одинаковы.

Простое голосование представляет собой достаточно эффективную процедуру принятия коллективного решения, если достоверности источников мало отличаются между собой. Если такое различие существенно, следует использовать правило взвешенного голосования, которое реализуется при выполнении следующего условия:

$$P_{ijl} = \frac{1 - P_{ijl}}{M - 1}; \quad i \neq j; \quad i, j = \overline{1, M}.$$

При этом каждому «голосу» приписывается свой «вес»:

$$C_{ijl} = A \lg \frac{P_{ijl}}{P_{ijl}}; \quad C_{ijl} = 0.$$

4.5.2. Анализ эффективности классификации

С целью получения самых общих представлений о повышении эффективности классификации ПРЦ за счет комплексирования данных от разных средств наблюдения рассмотрим зависимость вероятности правильного распознавания (ВПР) всей системы в целом (P_ϵ) от ВПР одного СН (P_p) при разном количестве источников информации L . В частности, на рис. 4.12 приведена названная зависимость для алгоритма простого голосования. Из рисунка следует, что для получения итоговой вероятности $P_\epsilon > 0,9$ при наличии 6 независимых средств наблюдения частная

вероятность правильной классификации каждым СН должна быть не менее 0,7. В некоторых случаях процедуры простого голосования снижают итоговую ВПР. Так, например, при объединении трех СН, из которых два имеют ВПР, равную 0,4, а один – 0,9 при простом голосовании $P_e < 0,7$, а при взвешенном больше 0,9.




Рис. 4.12. Зависимости вероятности правильного распознавания при простом голосовании от вероятности правильного распознавания при принятии решения по одному наблюдению

Конкретный пример применения алгоритма коллективного распознавания рассмотрим для ситуации объединения данных радиолокационной и радиотехнической разведки. Предположим, что классификатор располагает следующими источниками информации.

1. Станция РТР, определяющая класс ПРЦ по параметрам частотной модуляции принимаемого сигнала, вызванной килевой и бортовой качками ПРЦ при использовании электронной стабилизации луча РЛС.

2. РЛС с синтезированной апертурой, определяющая класс ПРЦ по его радиолокационному изображению. Причем сведения о классе ПРЦ, формируемые РСА могут быть получены неоднократно на разных витках орбиты носителя РСА. Эти сведения считаются статистически независимыми.

Эффективность каждого СН оценивается матрицей вероятностей правильных и ошибочных решений.

$$P = \begin{pmatrix} P_{A/A} & P_{K/A} & P_{Э/A} \\ P_{A/K} & P_{K/K} & P_{Э/K} \\ P_{A/Э} & P_{K/Э} & P_{Э/Э} \end{pmatrix}.$$

Цифровое моделирование алгоритма классификации по данным средств РТР [7], для одной из возможных практических ситуаций, позволило получить следующую матрицу:

$$P = \begin{pmatrix} 0,88 & 0,12 & 0,0 \\ 0,15 & 0,78 & 0,07 \\ 0,0 & 0,28 & 0,72 \end{pmatrix}.$$

Для второго из используемых средств наблюдения – РСА. Выделим две типовых ситуации, исследованных методом статистического моделирования при использовании в качестве прототипа тактико-технических характеристик космического аппарата SEASAT. При высокой эффективности (отношение сигнал/шум на выходе линейной части приемника составляет величину порядка 20 дБ) оценка матрицы вероятностей правильной и ошибочной классификации была получена в следующем виде:

$$P_2^{(1)} = \begin{pmatrix} 0,95 & 0,04 & 0,01 \\ 0,03 & 0,85 & 0,12 \\ 0,00 & 0,09 & 0,91 \end{pmatrix}.$$

При низком отношении сигнал/шум (порядка 14 дБ) оценка матрицы имеет вид:

$$P_2^{(2)} = \begin{pmatrix} 0,65 & 0,22 & 0,13 \\ 0,18 & 0,49 & 0,33 \\ 0,10 & 0,27 & 0,63 \end{pmatrix}.$$

Используя приведенные данные о достоверности различных СН, моделировались разные ситуации коллективного распознавания. Предполагалось, что от каждого источника поступает информация о номере выбранного класса. Сравнивались, два правила принятия решения: простое

голосование и взвешенное суммирование, причем ври взвешенном суммировании матрицы вероятностей, описывающие эффективность различных средств наблюдения, предполагались известными. Результаты моделирования сведены в табл. 4.2. В первом ее столбце приведены обозначения матриц, вероятностей используемых источников. Цифра перед матрицей указывает на число независимых СН (при моделировании изменялось количество решений, принимаемых на основе РСА).

Таблица 4.2

Матрицы вероятностей правильных решений

Комбинация СН	Простое голосование	Взвешенное суммирование
$P_1, 1P_2^{(1)}$	0,91 0,08 0,01 0,09 0,82 0,09 0,00 0,18 0,82	0,95 0,05 0,00 0,03 0,81 0,16 0,00 0,03 0,97
$P_1, 2P_2^{(1)}$	0,99 0,01 0,00 0,02 0,94 0,04 0,00 0,05 0,95	0,99 0,01 0,00 0,01 0,95 0,03 0,00 0,05 0,95
$P_1, 6P_2^{(2)}$	0,91 0,07 0,02 0,07 0,72 0,21 0,01 0,14 0,85	0,94 0,06 0,00 0,05 0,82 0,13 0,00 0,13 0,87
$P_1, 10P_2^{(2)}$	0,94 0,05 0,01 0,05 0,75 0,20 0,00 0,10 0,90	0,97 0,03 0,00 0,04 0,89 0,07 0,00 0,13 0,87
$P_1, 14P_2^{(2)}$	0,98 0,02 0,00 0,03 0,78 0,19 0,00 0,06 0,94	0,98 0,02 0,00 0,02 0,91 0,07 0,00 0,07 0,93

Из анализа результатов моделирования можно сделать следующие выводы. Если имеются два источника информации с разными матрицами вероятностей верных и ошибочных решений, то при простом голосовании итоговая матрица оказывается «средней» между исходными матрицами. При взвешенном суммировании итоговая матрица будет, по крайней мере,

не хуже, чем любая из исходных. При простом голосовании вероятность ошибки с ростом числа «плохих» источников информации может даже увеличиваться, если в коллективе распознающих автоматов наряду с источником, обладающим высокой достоверностью, присутствуют «плохие» СН, имеющие низкую эффективность классификации.

Правило взвешенного суммирования при тех же условиях обеспечивает гарантированный выигрыш по отношению к самому «хорошему» средству наблюдения, используемому вне коллектива решающих правил. Платой за такой выигрыш является априорное знание достоверности классификации ПРЦ каждым средством наблюдения.

Названные сведения не могут быть получены иначе, чем в результате оценки эффективности каждого классификатора либо по рабочим, либо экспериментальным, либо моделируемым выборкам наблюдаемых данных.

4.6. Методика расчета вероятности правильного распознавания при объединении решений отдельных СН методом простого голосования

Рассмотрим задачу расчета матрицы вероятностей правильных и ошибочных решений при условии, что частные решения выносятся одинаковыми средствами наблюдения методом простого голосования. Число объединяемых решений P . Априорные вероятности P_j наблюдения каждого типа ПРЦ известны. Число классов, как и в предыдущих случаях, равно трем. Предположим, что в пользу j -го класса принято n_j частных решений. Общее число объединяемых решений – N . Тогда вероятность возникновения конкретной ситуации совмещения n_1 , n_2 и $n_3 = N - (n_1 + n_2)$ частных решений при наблюдении цели 1-го класса равна $C_N^{n_1} C_{N-n_1}^{n_2} P_{1j}^{n_1} P_{2j}^{n_2} P_{3j}^{N-n_1-n_2}$.

Следует заметить, что при использовании простого голосования могут возникнуть конфликтные ситуации, когда справедливо одно из следующих условий

$$\begin{aligned} n_1 = n_2 > n_3; \\ n_1 = n_3 > n_2; \\ n_2 = n_3 > n_1 \end{aligned} \tag{4.6.1}$$

или

$$n_1 = n_2 = n_3 = N/3. \tag{4.6.2}$$

Предположим, что разрешение конфликтных ситуаций производится случайным образом. При этом в ситуациях (4.6.1) конфликт между j -м и r -м классами разрешается в пользу j -го класса с вероятностями $P_{k2}(j/r)$, которые представлены в виде матрицы:

$$P_{k2} = \begin{pmatrix} 0 & P_{k2}(1/2) & P_{k2}(1/3) \\ P_{k2}(2/1) & 0 & P_{k2}(2/3) \\ P_{k2}(3/1) & P_{k2}(3/2) & 0 \end{pmatrix}.$$

для элементов которой справедливо условие

$$P_{k2}(j/r) + P_{k2}(r/j) = 1 \quad \text{при } j \neq r.$$

Конфликтные ситуации типа (4.6.1) с вероятностью $P_{k3}(j)$ разрешаются в пользу j -го класса. При этом справедливо равенство

$$P_{k3}(1) + P_{k3}(2) + P_{k3}(3) = 1.$$

Используя введенные предположения, для вероятности вынесения итогового решения в пользу j -го класса при наблюдении цели i -го класса можно воспользоваться выражением:

$$P_N(j/i) = \sum_{n_j=0}^N \sum_{n_r=0}^{N-n_j} C_N^{n_j} C_{N-n_j}^{n_r} P_{ji}^{n_j} P_{ri}^{n_r} P_{qi}^{N-n_j-n_r} \times A(N, n_j, n_r),$$

где $r \neq j$, $r \neq q$, $q \neq j$.

Коэффициент $A(N, n_j, n_r)$ принимает следующие значения:

$$A(N, n_j, n_r) = \left\{ \begin{array}{ll} 0 & \text{если } n_j < n_r \quad \text{или } n_j < \frac{N-n_r}{2} \\ 1 & \text{если } n_j > n_r \quad \text{и } n_j > \frac{(N-n_r)}{2} \\ P_{k2}\left(\frac{j}{r}\right) & \text{если } n_j = n_r \quad \text{и } n_j > \frac{N}{3} \\ P_{k2}\left(\frac{j}{q}\right) & \text{если } n_j = \frac{N-n_r}{2} \quad \text{и } n_j > n_r \\ P_{k3}(j) & \text{если } n_j = n_r = \frac{N}{3} \end{array} \right\}.$$

Вероятность правильного распознавания ПРЦ на основе частных решений определяется в соответствии с выражением

$$P_{\text{пр.}N} = \sum_{i=1}^3 P_i P_N \left(\frac{1}{i} \right).$$

4.7. Литература к главе 4

1. Ван Трис Г. Теория обнаружения, оценок и модуляции: в 3 т. / Г. Ван Трис. М.: Сов. радио, 1972. т. 1. 744 с.
2. Растрингин Л.А. Метод коллективного распознавания / Л.А. Растрингин, Р.Х. Эринштейн. М.: Энергоиздат, 1981. 80 с.
3. Корн Г. Справочник по математике для научных работников и инженеров / Г. Корн, Т. Корн. М.: Наука, 1977. 832 с.
4. Ван Трис Г. Теория обнаружения, оценок и модуляции. В 3 т. Т. 3 / Г. Ван Трис. М.: Сов. радио. 1977. т. 3. 664 с.
5. Терраин Ч.У. Алгоритмы анализа изображений, основанные на статистических моделях / Ч.У. Терраин, Т.Ф. Куатьери, Д.Е. Даржон. ТИИЭР. 1986. т. 72. №4. С. 4-26.
6. Л.Г. Доросинский. Использование граничных соотношений Кайлата для оценки эффективности классификации сигналов. 24-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 7–13 сентября 2014.
7. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография – М.: Издательский дом Академии Естествознания, 2017.-212с.
8. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018.-264 с.

5. ИЗМЕРЕНИЕ ПАРАМЕТРОВ РЛИ

5.1. Измерение общегрупповых параметров распределенной цели. Измерение координат центра РЛИ

При решении задачи классификации, сопровождения траектории движения порядка ПРЦ или отдельной цели неизбежно возникает задача определения ряда общегрупповых параметров, таких как координата центра порядка (центра РЛИ ПРЦ), количество целей в составе порядка («блестящих точек» в составе ПРЦ), размеры порядка (размеры РЛИ ПРЦ), скорость и направление движения, ракурс и т. п.

Отличие методов решения задачи измерения параметров движения одиночного ПРЦ или порядка в целом имеет не принципиальный, а количественный характер, поскольку как в одном, так и в другом случаях наблюдаемые данные представляют собой совокупность двумерных отсчетов, характеризующих распределение мощности отраженного сигнала по координатам плоскости, занимаемой порядком ПРЦ (при относительно низком разрешении) или отдельно взятым объектом (в случае высокой разрешающей способности). Отличие процедур измерения общегрупповых параметров определяется по-существу размерами области наблюдения: локальная область, сравнимая по размерам с РЛИ ПРЦ, или радиолокационное изображение области акватории, в пределах которой находится наблюдаемый порядок. В связи с названными соображениями теоретическая часть синтеза и анализа проблемы определения общегрупповых параметров излагается в общем виде без конкретизации тактической задачи.

5.1.1. Синтез оптимального измерителя общегруппового параметра групповой цели

В настоящем разделе рассмотрено решение задачи оптимального измерения координаты общегруппового центра распределенной цели. Вся доступная информация о пространственном положении цели содержится в апостериорной плотности вероятности $P(\bar{x}_ц; \bar{x}_1 \dots \bar{x}_n; n)$, где $\bar{x}_ц$ – координата

общегруппового центра цели, n – число отсчетов полученного РЛИ, $\bar{x}_1 \dots \bar{x}_n$ – пространственные координаты отдельных элементов группы относительно общегруппового центра.

Определяющее значение для решения задачи синтеза устройства оценки общегруппового центра имеет апостериорная плотность вероятности

$$P(x_{ц}) = P(x_{ц}; n; x_1 \dots x_n)_{n, \bar{x}}, \quad (5.1.1)$$

поскольку принятие решения заключается в определении какого-либо параметра названной плотности (математического ожидания, моды и т.д.), выбор которого зависит от принятого критерия (минимум среднеквадратической ошибки, максимум апостериорной вероятности и т.п.).

В выражении (5.1.1) усреднение производится по всем возможным значениям как числа элементов цели, так и комбинациям их пространственных координат.

При заданной априорной вероятности $P(\bar{x}_{ц})$ и коэффициенте правдоподобия $\Delta(\bar{U}/\bar{x}_{ц})$ выражение апостериорной плотности вероятностей определяется по формуле Байеса

$$P(\bar{x}_{ц}) = CP(\bar{x}_{ц})\bar{\Delta}(\bar{U}/\bar{x}_{ц}), \quad (5.1.2)$$

где $\bar{U}$ – вектор комплексных амплитуд наблюдаемых данных.

Коэффициент правдоподобия в формуле (5.1.2) определяется статистическим усреднением частного коэффициента правдоподобия $\Delta(\bar{U}/\bar{x}_{ц}; x_1, x_2, \dots, x_n)$, записанного в предположении, что координаты элементов цели известны и фиксированы, по всем возможным значениям вектора $\bar{x}_n = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n)$ координат отдельных точек ПРЦ

$$\bar{\Delta}(\bar{U}/\bar{x}_{ц}) = \left\langle \Delta(\bar{U}/\bar{x}_{ц}; \bar{x}_1, \bar{x}_2, \dots, \bar{x}_n)_{\bar{x}_n} \right\rangle. \quad (5.1.3)$$

Усреднение в (4.1.3) производится по плотностям вероятности

$$\pi_n(\bar{x}_1, \dots, \bar{x}_n; \Omega/\bar{x}_{ц}), \quad (5.1.4)$$

содержание которых заключается в следующем. Вероятность ΔP_n нахождения в области пространства Ω , занятой целью, ровно n целей, координаты которых попали в интервалы

$$(\bar{x}_1, \bar{x}_1 + \bar{\Delta}_1), \dots, (\bar{x}_n, \bar{x}_n + \bar{\Delta}_n)$$

при условии, что координата центра цели $\bar{x}_{11}$, с точностью до величин второго порядка малости относительно $\bar{\Delta} = \max_{1 \leq j \leq n} \bar{x}_j$, выражаются в виде

$$\Delta P_n = \pi_n(\bar{x}_1, \dots, \bar{x}_n; \Omega) \bar{\Delta}_1, \dots, \bar{\Delta}_n [1 + o(\bar{\Delta})]. \quad (5.1.5)$$

При сделанных предположениях операция усреднения (5.1.3) может быть конкретизирована следующим образом:

$$\Delta[\bar{U}/\bar{x}_{11}] = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \Delta_n(\bar{x}_n) \pi(\bar{x}_n/\bar{x}_{11}) d\bar{x}_n. \quad (5.1.6)$$

Индекс (n) под интегралом указывает на его кратность, причем область интегрирования равна Ω -интервалу возможных координат элементов цели.

Если сигналы разрешены по каждой из своих координат, то справедливо выражение:

$$\Delta_n(\bar{x}_n) = \prod_{i=1}^n \Delta_1(\bar{U}, \bar{x}_i) \quad (5.1.7)$$

и, следовательно, для (4.1.6) можно записать:

$$\Delta[U/\bar{x}_n] = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \left\{ \prod_{i=1}^n \Delta_1(\bar{U}, \bar{x}_i) \right\} \pi_n(\bar{x}_n/\bar{x}_{11}), \quad (5.1.8)$$

где $\Delta_1(\bar{U}, \bar{x}_i)$ – коэффициент правдоподобия для цели, состоящей из одного элементарного отражателя с пространственной координатой $\bar{x}_i$.

В соответствии с методикой [1–3] более удобной по сравнению с (5.1.4) вероятностной характеристикой для задания расположения элементов ПРЦ может служить производящий функционал

$$L(u) = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \pi\left(\frac{\bar{x}_n}{\bar{x}_{11}}\right) \prod_{i=1}^n [u(\bar{x}_i) + 1] d\bar{x}_n. \quad (5.1.9)$$

Производящий функционал (5.1.9) позволяет выразить апостериорные характеристики многоэлементной цели в более компактной форме для ряда важных случаев. Это, в первую очередь относится к тем статистическим ситуациям, когда: цели разрешены по всем координатам, а априорные координаты отдельных элементов групповой цели представляют собой поток Пуассона или Бернулли.

Во избежание громоздких выкладок в дальнейшем подробно рассмотрим задачу в одномерном варианте, а именно, определим алгоритм оценки одной координаты общегруппового параметра цели (центра ПРЦ) и оценим его эффективность для ряда важных практических приложений. Такой подход по существу не снижает общности основных выводов и рекомендаций существенно упрощая решение задачи синтеза и анализа.

Сравнивая выражения (5.1.8) и (5.1.9), нетрудно установить следующее соотношение:

$$\Delta \left[\frac{\bar{U}}{x_{ц}} \right] = L \left[\Delta_1(u) - \frac{1}{x_{ц}} \right]. \quad (5.1.10)$$

Априорная информация о координатах отдельных элементов групповой цели задается ниже в двух вариантах:

- а) координаты отдельных целей представляют собой поток Пуассона;
 - б) координаты отдельных целей аппроксимируются потоком Бернулли.
- Для потока Пуассона производящий функционал получен в [2]:

$$L[u] = \exp \left\{ \int_{\Omega} \beta(x) u(x) dx \right\}, \quad (5.1.11)$$

где $\beta(x)$ – интенсивность пуассоновского потока, заданная как функция от координаты цели.

Сравнение выражений (5.1.11) и (5.1.10) позволяет непосредственно получить выражение для усредненного коэффициента правдоподобия при моделировании отсчетов РЛИ ПРЦ пуассоновским потоком

$$\Delta \left[\bar{U}/x_{ц} \right] = \exp \left\{ \int_{\Omega} \beta(x/x_{ц}) \left[\Delta_1(\bar{U}, x) - 1 \right] dx \right\}. \quad (5.1.12)$$

Принятое для интенсивности потока обозначение $\beta(x/x_{\Pi})$ подчеркивает зависимость интенсивности от измеряемого параметра – координаты центра сложной цели x_{Π} .

Для другого частного случая, когда поток координат элементов поверхности РЛИ ПРЦ аппроксимирован потоком Бернулли, выражение производящего функционала имеет вид:

$$L[u] = \prod_{j=1}^k \left[1 + \int_{\Omega} u(x) e_j(x) dx \right], \quad (5.1.13)$$

где k – максимальное число отдельных элементов групповой цели (число элементов разрешения, приходящихся на цель максимально возможных размеров);

$e_j(x)$ – парциальная плотность вероятности наличия отражающего элемента на j -й позиции (с номером j), не обязательно нормированная к единице, то есть

$$\int_{\Omega} e_j(x) dx = v_j \leq 1, \quad (5.1.14)$$

что допускает отсутствие отражающего элемента цели в j -м элементе разрешения с вероятностью

$$\mu_j = 1 - v_j. \quad (5.1.15)$$

Сравнение выражений (5.1.10) и (5.1.13) позволяет получить коэффициент правдоподобия

$$\Delta[\bar{U}/x_{\Pi}] = \prod_{j=1}^k \left[1 + \int_{\Omega} e_j(x/x_{\Pi}) [\Delta_1(\bar{U}, x_{\Pi}) - 1] dx \right]. \quad (5.1.16)$$

С учетом (5.1.14) и (5.1.15) последнее выражение может быть записано в следующем виде

$$\Delta[\bar{U}/x_{\Pi}] = \prod_{j=1}^k \left[\mu_j(x) + \int_{\Omega} e_j(x/x_{\Pi}) \Delta_1(\bar{U}, x) dx \right]. \quad (5.1.17)$$

В тех случаях, когда решение принимается по критерию максимума апостериорной плотности вероятности, оценка координаты центра цели находится из выражения

$$\hat{x}_{Ц} = \operatorname{argmax} \left\{ \ln P(x_{Ц}) + \ln \Delta \left[\frac{\bar{U}}{x_{Ц}} \right] \right\} \quad (5.1.18)$$

и определяется формулами:
для пуассоновского потока

$$\hat{x}_{Ц} = \operatorname{argmax} \left\{ \ln P(x_{Ц}) + \int_{\Omega} \beta(x/x_{Ц}) [\Delta(\bar{U}, x) - 1] dx \right\}; \quad (5.1.19)$$

для потока Бернулли

$$x_{Ц} = \operatorname{argmax} \left\{ \ln P(x_{Ц}) + \sum_{j=1}^k \ln \left[\mu_j(x) + \int_{\Omega} e_j(x/x_{Ц}) \Delta_1(\bar{U}, x) dx \right] \right\} \quad (5.1.20)$$

Соответствующие схемы изображены на рис. 5.1 и на рис. 5.2.




Рис. 5.1. Блок-схема измерителя координаты центра (поток Пуассона)

Как в том, так и другом случае основная функциональная операция состоит в обобщении данных оптимальных приемников первичной обработки (интегрировании по ожидаемой протяженности цели с весами, определяемыми априорным изменением интенсивности потока с соответствующим «загрублением» разрешающей способности).




Рис. 5.2. Блок-схема измерителя координаты центра (поток Бернулли)

Таким образом, для построения классического байесовского измерителя необходимо априорное знание интенсивности потока $\beta(x/x_{11})$ или парциальных плотностей $e(x)$, которые должны рассчитываться, исходя из принятых моделей отдельных ПРЦ и/или тактики построения.

5.1.2. Анализ эффективности алгоритма измерения координаты центра ПРЦ

Оценка максимума апостериорной вероятности образуется путем выбора канала формирования $\dot{P}(x_{11})$, в котором апостериорная плотность вероятности принимает максимальное значение. В частности, если известно приближение x'_{11} к истинному значению x_{11} , отстоящее от последнего меньше, чем на величину апостериорного среднеквадратичного разброса, удобно аппроксимировать $\ln \dot{P}(x'_{11})$ квадратичным разложением относительно точки x'_{11} :

$$\ln \dot{P}(x_{11}) \cong \ln \dot{P}(x'_{11}) + \frac{d \ln \dot{P}(x'_{11})}{dx_{11}}(x - x'_{11}) + \frac{d^2 \ln \dot{P}(x'_{11})}{dx_{11}^2}(x - x'_{11})^2. \quad (5.1.21)$$

После дифференцирования по $x_{ц}$ получаем решение уравнение правдоподобия

$$\hat{x}_{ц} = x'_{ц} - \frac{\frac{d}{dx_{ц}} \ln \dot{P}_1(x'_{ц})}{\frac{d^2}{dx_{ц}^2} \ln \dot{P}_1(x'_{ц})}. \quad (5.1.22)$$

При относительно невысокой априорной точности, когда априорное распределение практически неизменно в окрестности пика коэффициента правдоподобия $\Delta[\bar{U}/x_{ц}]$, переходим к оценкам максимального правдоподобия. При этом дисперсия оценки определяется соотношением

$$\sigma_{x_{ц}}^2 = -M \left\{ \left[\frac{d \ln \dot{P}(U/x_{ц})}{dx_{ц}} \right] \right\}. \quad (5.1.23)$$

Применяя известную методику расчета дисперсии оценки [1], при аппроксимации последовательности отметок от цели пуассоновским потоком получим для нее следующее выражение:

$$\sigma_{x_{ц}}^{-2} = 2 \iint_{\Omega} \beta' \left(\frac{x_1}{x_{ц}} \right) \beta' \left(\frac{x_2}{x_{ц}} \right) \sqrt{q(x_1) q(x_2)} \psi(x_1, x_2) dx_1 dx_2, \quad (5.1.24)$$

где $q(x)$ – отношение сигнал/шум, заданное как функция от координат цели; $\psi(x_1, x_2)$ – функция неопределенности, определяемая в соответствии с соотношением (4.3.19).

Дальнейшую конкретизацию выражения (5.1.24) проведем при следующих предположениях:

- 1) отношение сигнал/шум не зависит от координат цели, а необходимые энергетические соотношения учтены при определении интенсивности потока $\beta(x)$, которая, в свою очередь, представляет собой симметричную функцию;
- 2) оцениваемый общегрупповой параметр $x_{ц}$ представляет собой координату центра интенсивности $\beta(x)$.

Для получения простых выражений, позволяющих произвести предварительную оценку эффективности определения общегруппового центра цели рассмотрим два частных случая.

1. При достаточно высоком разрешении воспользуемся аппроксимацией функции неопределенности

$$\psi(x_1, x_2) = \Delta_\Phi \delta(x_1 - x_2). \quad (5.1.25)$$

Тогда,

$$\sigma_{x_{II}}^{-2} = 2\Delta\psi \int_{\Omega} [\beta'(x - x_{II})]^2 q(x) dx. \quad (5.1.26)$$

При постоянном значении отношения сигнал/шум: $p = \text{const}$

$$\sigma_{x_{II}}^2 = \frac{\Delta_{\beta I}^2}{2q_{3\Phi\Phi}}, \quad (5.1.27)$$

где

$$\Delta_{\beta I} = \frac{\sqrt{\int_{\Omega} \beta^2(x - x_{II}) dx}}{\int_{\Omega} [\beta'(x - x_{II})]^2 dx} \quad (5.1.28)$$

– эффективная протяженность групповой цели,

$$q_{3\Phi\Phi} = q\Delta_\Phi \int_{\Omega} \beta^2(x - x_{II}) dx \quad (5.1.29)$$

– эффективное общегрупповое отношение сигнал/шум.

2. В этом примере используем гауссовские функции для аппроксимации интенсивности потока и сигнальной функции (при вычислении функции неопределенности):

$$\beta(x) = L \exp\left[-\frac{x^2}{2\Delta_{\beta I}^2}\right], \quad (5.1.30)$$

$$u(x) = M \exp\left[-\frac{x^2}{2\Delta_u^2}\right], \quad (5.1.31)$$

где коэффициенты L и M определяются из условий нормировки:

$$\int_{\Omega} \beta(x) dx = \langle n \rangle; \quad (5.1.32)$$

$$\int_{\Omega} u^2(x) dx = 1. \quad (5.1.33)$$

После подстановки последних выражений в (5.1.24) получим:

$$\sigma_{x_{II}}^2 = \frac{\Delta_{\beta I}^2}{2p\langle n \rangle^2} \frac{\left[1 + \left(\frac{\Delta_{\beta I}}{\Delta_u} \right)^2 \right]^{3/2}}{\left(\frac{\Delta_{\beta I}}{\Delta_u} \right)^2}. \quad (5.1.34)$$

Минимум дисперсии оценки достигается при условии $\frac{\Delta_{\beta I}}{\Delta_u} = \sqrt{2}$ и равен

$$\sigma_{x_{II}}^2 = 2,6 \frac{\Delta_{\beta I}^2}{2q\langle n \rangle^2}. \quad (5.1.35)$$

Несмотря на частный характер последних соотношений, можно сделать вывод достаточно общего характера: при определении центра группы мало связанных между собой слабых сигналов целесообразно иметь средство наблюдения с разрешающей способностью, сравнимой по размерам с эффективным размером группы. В практически важных случаях, связанных с классификацией ПРЦ, когда требуемая разрешающая способность существенно выше, оптимальный алгоритм определения центра формирует «стробы», «загрубляющие» разрешение до требуемой величины.

При использовании для моделирования отсчетов сигнала от цели в виде потока Бернулли для дисперсии оценки координаты центра получим аналогичное выражение

$$\sigma_{x_{II}}^{-2} = 2 \sum_{j=1}^k \iint_{\Omega} e'_j(x_1/x_{II}) e'_j(x_2/x_{II}) \sqrt{q(x_1)q(x_2)} \Psi(x_1, x_2) dx_1 dx_2. \quad (5.1.36)$$

Предположим, что внутригрупповые сигналы могут находиться только на вполне определенных позициях, то есть:

$$e_j \left(\frac{x}{x_{II}} \right) = v_j \delta(x - \Delta_j - x_{II}) \quad (5.1.37)$$

и считая $\psi(x_1, x_2) = \psi(x_1 - x_2)$, получим:

$$\sigma_{x_{\text{ц}}}^{-2} = \sum_{j=1}^k v_j^2 \frac{2q_j}{\Delta_{\Phi}}, \quad (5.1.38)$$

где Δ_{Φ} – ширина интервала разрешения,

q_j – отношение сигнал/шум в j -м интервале разрешения.

Формула (5.1.38) отражает в основном те же качественные особенности измерения общегруппового центра, что и при использовании потока Пуассона. Точность растет при увеличении отношения сигнал/шум и среднего числа элементарных целей. В то же время дисперсия увеличивается при увеличении числа элементов разрешения, приходящихся на размер групповой цели (при увеличении отношения протяженности цели к величине элемента разрешения).

5.2. Литература к главе 2

1. Большаков И.А. Статистические проблемы выделения потока сигналов из шума / И.А. Большаков. М.: Сов. радио 1969. 464 с.
2. Доросинский Л.Г. Измерение общегрупповых параметров потока сигналов / Л.Г. Доросинский, С.П. Литвиненко, Л.Н. Шалимов // Естественные и технические науки №4 (54). Москва. 2011.
3. Dorosinskiy L.G. The research of the distributed objects' radar image recognition algorithms. Applied and Fundamental Studies. Proceedings of the 2st International Academic Conference. March 8-10, 2013, St. Louis, Missouri USA, vol. 1. pp.211-214.

6. СИНТЕЗ ОПТИМАЛЬНЫХ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ПРЦ

Распознаванию пространственно-распределённой цели (ПРЦ) по данным космического мониторинга, осуществляемого РЛС с синтезированной апертурой, должно предшествовать обнаружение названной цели. Распределённый многоточечный характер цели приводит к необходимости решения задачи оптимального синтеза алгоритма обнаружения, который оказывается чрезвычайно громоздким из-за необходимости перебора всех априори возможных ситуаций расположения так называемых «блестящих» точек и характеристик отражённых от них сигналов [1, 2, 7].

Кроме того, следует иметь в виду, что оптимальный обнаружитель должен иметь в своём составе блок апостериорного оценивания параметров ПРЦ [4].

6.1. Синтез оптимального алгоритма обнаружения ПРЦ при наличии в объеме разрешения не более одного элемента

Пусть выполнено условие попадания не более одного элемента ПРЦ в любой объем разрешения. Максимальное число обнаруживаемых элементов $M_{\text{макс}}$ ограничено количеством L интервалов разрешения по дальности в области наблюдения. Число возможных расположений наблюдаемого количества $M \leq M_{\text{макс}}$ элементов среди L интервалов равно числу сочетаний из L по M , поэтому общее выражение принимает вид:

$$P\left(\frac{\vec{l}}{\tau_0^k}\right) = \sum_{q=1}^{\binom{L}{M}} P\left(\frac{\vec{l}_q}{\tau_0^k}\right) \delta(\vec{l} - \vec{l}_q). \quad (6.1.1)$$

В дальнейшем предполагается, что случайное число элементов за время наблюдения не изменяется.

Оптимальная процедура принятия решения о наличии или отсутствии ПРЦ заключается в сравнении с порогом усредненного отношения правдоподобия.

$$\Lambda(y) = \left\langle \Lambda\left(\frac{y}{M}, \tau_0^1, \dots, \tau_0^N, \overline{\tau^1}, \dots, \overline{\tau^N}\right) \right\rangle M, \tau_0^1, \dots, \tau_0^N, \overline{\tau^1}, \dots, \overline{\tau^N}, \quad (6.1.2)$$

вычисляемого по всем существенным и несущественным параметрам отношения правдоподобия, записанного в предположении, что параметры фиксированы [5] для сигналов вида:

$$y(t, \tau) = \operatorname{Re} \left\{ \sum_{i=1}^M \vartheta_i(t) \psi(\tau - \tau_i, 0) \right\} + n(t), \quad (6.1.3)$$

где $n(t)$ – белый шум.

С учетом предположения о статистической независимости флуктуаций элементов ПРЦ отношение правдоподобия при фиксированном положении известного числа M имеет вид:

$$\Lambda(y / M, \tau_0^1, \dots, \tau_0^N, \overline{\tau^1}, \dots, \overline{\tau^N}) = \prod_{k=1}^N \prod_{i=1}^M \Lambda \left(\frac{y}{\tau_0^k \tau_i^k} \right), \quad (6.1.4)$$

где τ_i^k – задержка сигнала, отраженного от i -го элемента в k -ом периоде.

После несложных преобразований получим:

$$\begin{aligned} \Lambda(y) = & \sum_{M=1}^{M_{\max}} P(M) \int \dots \int \left\{ \prod_{k=1}^N \prod_{i=1}^M \Lambda \left(\frac{y}{\tau_0^k \tau_i^k} \right) P(\tau_0^1) \prod_{k=2}^N P \left(\frac{\tau_0^k}{\tau_0^{k-1}} \right) \right\} \times \\ & \times P \left(\frac{\tilde{l}}{\tau_0^k} \right) P \left(\frac{\overline{\tau^k}}{\tilde{l} \tau_0^k} \right) d\tau_0^1, \dots, d\tau_0^N. \end{aligned} \quad (6.1.5)$$

Далее предполагаем, что $P(\tilde{l} / \tau_0^k)$ не зависит от τ_0^k , т.е.

$$P(\tilde{l} / \tau_0^k) = P(\tilde{l}). \quad (6.1.6)$$

Указанное предположение означает, что элементы в группе сохраняют взаимное положение в течение всего времени наблюдения. Такая ПРЦ называется дружно движущейся. Кроме того, будем считать положение задержки τ_i внутри интервала разрешения независимым от того, как расположены задержки других элементов ПРЦ в своих интервалах разрешения:

$$P(\overline{\tau^k} / \tilde{l}, \tau_0^k) = \prod_{i=1}^M P(\tau_i^k / l_{q_i}, \tau_0^k). \quad (6.1.7)$$

При фиксированных величинах $\bar{l}$ и τ_0^k область определения i -го сомножителя в выражении (6.1.7) представляет собой интервал $[\tau_0^k + l_{q_i} \delta\tau, \tau_0^k + (l_{q_i} + 1)\delta\tau]$. Тогда

$$B_{q_{ik}} \left(\frac{y}{\tau_0^k} \right) = \int_{\tau_0^k + l_{q_i} \delta\tau}^{\tau_0^k + (l_{q_i} + 1)\delta\tau} P \left(\frac{\tau_i^k}{l_{q_i} \tau_0^k} \right) \Lambda \left(\frac{y}{\tau_0^k \tau_i^k} \right) d\tau_i^k. \quad (6.1.7)$$

Выражение (6.1.8) справедливо вследствие независимости принятых сигналов в соседних интервалах разрешения.

Если за время наблюдения (длительность пачки) дальность до ПРЦ не меняется ($\tau_0^k \approx \tau_0^1$, $k = \overline{1, N}$), то выражение (6.1.5) существенно упрощается:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} P(M) \sum_{q=1}^{\binom{L}{M}} P(\bar{l}_q) \int_{\{\Delta\tau\}} P(\tau_0^1) \exp \left\{ \sum_{i=1}^M \sum_{k=1}^N \ln B_{q_{ik}} \left(\frac{y}{\tau_0^1} \right) \right\} d\tau_0^1. \quad (6.1.8)$$

При записи формулы (6.1.9) использовано равенство:

$$\prod_{i=1}^M \Lambda_i = \exp \left\{ \sum_{i=1}^M \ln \Lambda_i \right\}. \quad (6.1.9)$$

Предположим, что вероятности каждого q -го сочетания одинаковы. Тогда алгоритм (6.1.9) станет более простым:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{\binom{L}{M}} \sum_{q=1}^{\binom{L}{M}} P(\tau_0^1) \exp \left\{ \sum_{i=1}^M \sum_{k=1}^N \ln B_{q_{ik}} \left(\frac{y}{\tau_0^1} \right) \right\} d\tau_0^1. \quad (6.1.10)$$

Поскольку дальность до характерной точки ПРЦ известна, т. е.

$$P(\tau_0) = \delta(t - \tau_0^1), \quad (6.1.11)$$

то оптимальный алгоритм обнаружения примет вид:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{\binom{L}{M}} \sum_{q=1}^{\binom{L}{M}} \exp \left\{ \sum_{i=1}^M \sum_{k=1}^N \ln B_{q_{ik}}(y) \right\}. \quad (6.1.12)$$

Впервые алгоритм (6.1.13) для частного случая был синтезирован в [3]. Структурная схема алгоритма (6.1.13) приведена на рис. 6.1. Она содержит $M_{\max}$ каналов, $2^{M_{\max}}$ сумматоров и экспонирующих устройств.

В i -ом канале имеется $\binom{L}{M} + 2$ сумматоров, $\binom{L}{M}$ экспонирующих устройств. На входы каждого из $\binom{L}{M}$ сумматоров сигналы поступают

в виде одной из $\binom{L}{M}$ комбинаций, которые могут иметь M сигналов среди L интервалов разрешения. При $M_{\max} \geq 8$ полученная расчётная схема нереализуема даже на специализированных ЭЦВМ. Она требует большой памяти и не может работать в реальном масштабе времени.

Определим вид оптимального алгоритма обнаружения ПРЦ при условии, что каждый из элементов с вероятностью P_i $\left(\sum_{i=1}^L P_i = 1 \right)$, может попасть в i -й интервал разрешения. Для некоторого $M \leq M_{\max}$ вероятности $P(\overline{l}_q)$ в (6.1.9) в этом случае равны

$$P(\overline{l}_q) = C_M^{-1} \prod_{i=1}^M P_{l_{q_i}}, \quad (6.1.13)$$

где нормирующий коэффициент

$$C_M = \frac{1}{M!} \sum_{\{\varepsilon\}} \prod_{i=1}^M P_{l_i}, \quad \{\varepsilon\} = \{1 \leq l_1 \leq \dots \leq l_M \leq L\}.$$

Очевидно, при $P_i = 1/L$, $i = \overline{1, L}$, вероятность отдельной комбинации

$$P(\overline{l}_q) = 1 / \binom{L}{M}.$$

Подставив (6.1.12) и (6.1.14) в выражение (6.1.9), получим оптимальный алгоритм обнаружения ПРЦ в более общем виде, чем выражение (6.1.13):

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{q=1}^L \prod_{i=1}^M P_{q_i} \exp \left\{ \sum_{i=1}^M \sum_{k=1}^N \ln B_{q_{ik}}(y) \right\} =$$

$$= \sum_{M=1}^{M_{\max}} w(M) \sum_{q=1}^L \exp \left\{ \sum_{i=1}^M \sum_{k=1}^N \ln B_{q_{ik}}(y) \right\},$$

где $w(M) = P(M) / C_M$.




Рис. 6.1. Структурная схема оптимального алгоритма обнаружения многоэлементной ПРЦ с разрешаемыми элементами

Структура оптимального алгоритма (6.1.15) по сравнению со структурой алгоритма (6.1.13) практически не изменилась. Здесь добавились лишь весовые множители у коэффициентов правдоподобия $B_{q_{ik}}(y)$. Число таких умножителей равно числу интервалов разрешения.

Предположим далее, что элементы ПРЦ расположены среди интервалов разрешения независимо от периода к периоду, т. е.

$$P\left(\frac{\vec{l}}{\tau_0^k}\right) = P(\vec{l})\delta(\tau - \tau_0^k). \quad (6.1.16)$$

Далее получим оптимальный алгоритм обнаружения ПРЦ с независимым межпериодным расположением элементов

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{\binom{L}{M}} \sum_{k=1}^N \sum_{q=1}^{\binom{L}{M}} \exp\left\{\sum_{i=1}^M \ln B_{q_{ik}}(y)\right\}. \quad (6.1.15)$$

Структурная схема оптимального алгоритма (6.1.17) представлена на рис. 6.2. По количественному составу и сложности она сравнима со структурной схемой алгоритма (6.1.13).

Наряду с обнаружением практически всегда встает задача измерения параметров обнаруженного объекта. Блок-схема алгоритма оценивания представлена на рис. 6.3 в виде двух блоков: блока получения апостериорного распределения $P_{ps}(M)$ и блока оценки числа элементов. Информация на первый блок поступает с выхода умножителей в виде сигналов r_{Mk} , $k = \overline{1, N}$, $M = \overline{1, M_{\max}}$. Апостериорная функция распределения числа элементов $P_{ps,k}(M)$ после обработки сигналов k -го периода находится нормировкой величин r_{Mk} :

$$P_{ps,k}(M) = \frac{r_{Mk}}{\sum_{M=1}^{M_{\max}} r_{Mk}}, \quad k = \overline{1, N}. \quad (6.1.16)$$

Апостериорное распределение k -го периода является априорным распределением для следующего $(k + 1)$ -го периода повторения. Во втором блоке на основании распределения находится оптимальная по некоторому критерию оценка числа элементов ПРЦ.




Рис. 6.2. Структурная схема оптимального алгоритма обнаружения хаотично движущейся ПБЦ с разрешаемыми элементами

Наиболее часто используемой оценкой является апостериорное среднее

$$\widehat{M}_N = \sum_{M=1}^{M_{\max}} MP_{ps,N}(M).$$

Если принимается решение об обнаружении ПРЦ, то ключ открывается и оценка $\widehat{M}_N$ поступает на выход блока оценивания. Подобная связь между алгоритмами оценивания и обнаружения называется «сильной связью» и подробно исследована в [4].




Рис. 6.3. Укрупненная схема одновременного обнаружения и оценивания числа элементов ПБЦ

Определение отношения правдоподобия $\ln B_{q_{ik}}(y)$ зависит от функций распределения случайных величин $y(\tau_{ik})$. При нормальном шуме сигнал с релейским законом флуктуаций амплитуды требует операции возведения в квадрат [6]:

$$\ln B_{q_{ik}}(y) = \frac{q}{2\sigma_0^2(1+g)} A^2 \left(\frac{y}{(\tau_{ik})} - \ln(1+g) \right), \quad (6.1.17)$$

где $A(y/\tau_{ik})$ – амплитуда огибающей при задержке τ_{ik} ;

g – отношение сигнал/шум по мощности на выходе линейной части приемника;

$2\sigma_c^2$ – мощность отраженного сигнала;

$2\sigma_0^2$ – дисперсия шума на входе приемника.

Логарифм отношения правдоподобия с райсовским распределением амплитуд задает более сложную нелинейную операцию – взятие логарифма модифицированной функции Бесселя нулевого порядка [6]:

$$\ln B_{q_{ik}}(y) = -\frac{a^2}{2} + \frac{A^2(y/\tau_{ik})}{2\sigma^2 b^2} + \ln I_0\left(\frac{aA(y/\tau_{ik})}{\sigma}\right) + \ln \frac{b^2}{1+b^2}, \quad (6.1.18)$$

где $b = \sigma_0/\sigma_c$; $a = \frac{a'}{\sqrt{1+b^2}}$; величина уровня когерентной составляющей a' , в котором $2\sigma_c^2$ – мощность диффузной составляющей отраженного сигнала, $\sigma = \sigma_c \sqrt{1+b^2}$. Отношение сигнал/шум для райсовской модели равно:

$$g = \frac{(a')^2/2+1}{b^2} = \frac{a^2(1+b^2)+2}{2b^2}. \quad (6.1.19)$$

Логарифм отношения правдоподобия для сигнала с m -распределением (5.25) имеет вид:

$$\ln B_{q_{ik}}(y) = -\ln \Gamma(m) + m \ln(1+\rho) + (m-1) \ln \left(A_n^2 \left(\frac{y}{\tau_{ik}} \right) \right) - \rho A_n^2 \left(\frac{y}{\tau_{ik}} \right), \quad (6.1.20)$$

где

$$\begin{cases} A_n \left(\frac{y}{\tau_{ik}} \right) = A \left(\frac{y}{\tau_{ik}} \right) / \sigma; \\ \rho = \frac{\sigma_0^2 m}{\sigma^2} - 1. \end{cases} \quad (6.1.21)$$

После подстановки (6.1.16) в выражение (6.1.13) получим оптимальный алгоритм обнаружения дружно движущейся ПРЦ с релейским распределением амплитуд

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} w(M) \sum_{q=1}^{\binom{L}{M}} \exp \left\{ \frac{g}{1+g} \sum_{i=1}^M \sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{ik}} \right) \right\}, \quad (6.1.22)$$

где $w(M) = \frac{P(M)}{\binom{L}{M} (1+g)^{MN}}$ – весовой коэффициент M го канала;

$$A_n \left(\frac{y}{\tau_{ik}} \right) = A \left(\frac{y}{\tau_{ik}} \right) / \sigma_0 \text{ – нормированная амплитуда.}$$

Введём обозначение результата накопления принятых за время наблюдения сигналов $x_i = \frac{g}{1+g} \sum_{k=1}^N A_y^2$ и представим алгоритм (6.1.24) в более компактной записи:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} w(M) \sum_{q=1}^{\binom{L}{M}} \exp \left\{ \sum_{i=1}^M x_{q_i} \right\}. \quad (6.1.23)$$

Вычисления статистики обнаружения может производиться рекуррентно:

$$\begin{aligned} S_1^{(i+1)} &= S_1^{(i)} + \exp(x_{i+1}); \\ S_2^{(i+1)} &= S_2^{(i)} + \exp(x_{i+1}) S_1^{(i)}; \\ &\dots\dots\dots \\ S_i^{(i+1)} &= S_i^{(i)} + \exp(x_{i+1}) S_{i-1}^{(i)}; \\ S_{i+1}^{(i+1)} &= \exp(x_{i+1}) S_i^{(i)}; \quad S_i^{(0)} = 0, \quad i = \overline{1, L}. \end{aligned} \quad (6.1.24)$$

Из (6.1.26) следует:

$$S_M^i = \sum_{q=1}^{\binom{L}{M}} \exp \left\{ \sum_{i=1}^M x_{q_i} \right\}, \quad i = \overline{1, L}, \quad M = \overline{1, L}. \quad (6.1.25)$$

Учитывая соотношение:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} w(M) S_M^{(L)}, \quad (6.1.26)$$

получим приведенную схему оптимального алгоритма (6.1.28), которая изображена на рис. 6.4. Как и в структурной схеме, изображённой на рис. 6.1, здесь также производится поканальная обработка, однако количество операционных блоков существенно меньше: $2M_{\max}$ сумматоров и умножителей. Эта схема также может быть дополнена блоком оценки числа элементов ПРЦ.

При ряде упрощений оптимальная статистика обнаружения вычисляется по свернутой приведенной схеме (рис. 6.5), где использованы соотношения

$$\Lambda(y) = Z_L, \quad (6.1.27)$$

$$\text{где} \quad \begin{cases} Z_1 = \exp(x_1)[1 + Z_0] + Z_{-1}; \\ \dots\dots\dots \\ Z_L = \exp(x_L)[1 + Z_{L-1}] + Z_{L-2}. \end{cases} \quad (6.1.28)$$




Рис. 6.4. Структура приведенной схемы оптимального алгоритма обнаружения




Рис. 6.5. Структура свернутой приведенной схемы

Модификация приведённой схемы реализована в виде, показанном на рис. 6.6.




Рис. 6.6. Структура частной приведенной схемы

Структурные и приведенные схемы не претерпят изменений при использовании других моделей радиолокационных сигналов.

6.2. Реализация и анализ оптимальных алгоритмов обнаружения и оценивания

Рассмотрим примеры реализации оптимального алгоритма обнаружения и оценивания ПРЦ с релеевским распределением амплитуд. Вернемся к приведенной схеме оптимальной обработки сигналов при условии, когда в одном объеме разрешения может быть не более одной точечной цели. Текущий граф этой схемы для трех соседних интервалов разрешения показан на рис. 6.7. Горизонтальные стрелки соответствуют сложению, наклонные – умножению на $\exp(x_i)$. Массив чисел $\bar{S}$ имеет переменную размерность, число его элементов равно числу принятых сигналов. Очевидно, максимальная размерность этого массива равна L – числу всех интервалов разрешения в области наблюдения. Реализация приведенной схемы, работающей согласно графу на рис. 6.7, требует L массивов различной размерности от 1 до L с общим объемом элементов $L(L + 1)/2$.




Рис. 6.7. Текущий граф приведенной схемы (6.26) при обработке сигналов от соседних объемов разрешения

Чтобы избежать использования таких объемов памяти, необходимо реализовать приведенную схему в другом, противоположном описанному этим графом направлении. Вычисление элементов массива $\bar{S}$ размерности L начинается с номера i , соответствующего номеру последнего интервала разрешения, «с конца» массива (см. рис. 6.8, а). Каждый следующий элемент (его номер на единицу меньше, чем предыдущий), определяется по формуле

$$S_r = S_r + \exp(x_i)S_{r-1}, \quad i = \overline{1, L}. \quad (6.29)$$




Рис. 6.8. Взаимные связи (а) и текущий граф (б) при реализации приведенной схемы с использованием одного массива

На рис. 6.8, б последовательность вычислений элементов изображена жирной линией, а связи между ними – тонкими. Большие дуги соответствуют умножению на $\exp(x_i)$ и сложению, малые – простому сложению. Перед началом наблюдения массив $\bar{S}$ обнуляется, $S_0 = 1$. Таким образом, для реализации приведенной схемы, кроме рабочей памяти, требуется L ячеек, то есть $\Pi_\lambda = L$.

При анализе алгоритмов оценивания в качестве начальных («априорных») были выбраны четыре распределения ($L = 8$):

1. Равномерное распределение:

$$P_{a_1}(M) = 0,125.$$

2. Распределение для малоэлементной ПРЦ:

$$P_{a_2}(M) = 0,737 \left(\frac{9-M}{8} \right)^9.$$

3. Распределение для многоэлементной ПРЦ;

$$P_{a_3}(M) = 0,737 \left(\frac{M}{8} \right)^9.$$

4. Квазигауссовое распределение ПРЦ:

$$P_{a_4}(M) = 0,393 \left(-\frac{(M-4,5)^2}{2} \right).$$

Было проведено исследование четырех характерных случаев количественного состава ПРЦ: а) $M = 1$; б) $M = 2$; в) $M = 4$; г) $M = 8$.

На рис. 6.9 показаны оценки распределений («апостериорные» распределения) числа элементов при обработке сигналов от ПРЦ, имеющих четыре элемента ($M = 4$). При отношении сигнал/шум $g = -3$ дБ (рис. 6.9, а) начальные распределения изменяются незначительно, оценка $P_{ps}(M)$ практически совпадает с $P_a(M)$ для $N = 1,16$. Если увеличить g в четыре раза ($g = +3$ дБ, рис. 6.9, б), то вид распределения $P_{ps}(M)$ с увеличением N изменяется уже существенно. Очень быстро стремится к действительному распределению

$$\left(P(M) = \begin{cases} 1, & M = 4 \\ 0, & M \neq 4 \end{cases} P_{ps}(M) \right)$$

при начальном равномерном распределении. Медленнее приближается $P_{ps}(M)$ к $P(M)$ при начальном квазигауссовом распределении. Оценки распределений $P_{ps}(M)$ при начальных втором и третьем, не показанном на рис. 6.9 распределениях, сходятся к действительному распределению значительно медленнее, чем при первом и втором.




Рис. 6.9. Оценки распределений при отношении сигнал/шум – 3 дБ (а), +3 дБ (б)

Анализ оптимального алгоритма оценивания показал:

1) если отношение информационного расхождения ΔI_1 между истинным и априорным к информационному расхождению ΔI_2 между истинным и равномерным менее 0,10–0,15, то оценивание проводить не нужно, т. к. априорное практически совпадает с истинным;

2) если это отношение заключено в пределах от 0,15 до 1, то в качестве начального следует использовать априорное распределение;

3) если это отношение превышает единицу, то в качестве начального следует выбрать равномерное распределение.

На основании этого вывода предлагается следующий комбинированный алгоритм оценивания:

Шаг 1. Получить апостериорное распределение $P_{ps_1}(M)$ при начальном распределении, соответствующем априорному $P_a(M)$.

Шаг 2. Получить апостериорное распределение $P_{ps_2}(M)$ при начальном распределении, соответствующем равномерному $P_p(M) = 1/M_{\text{макс}}$.

Шаг 3. Вычислить информационные расхождения

$$\Delta I_1 = \sum_{M=1}^{M_{\text{макс}}} P_a(M) \ln \frac{P_a(M)}{P_{ps_1}(M)};$$

$$\Delta I_2 = \sum_{M=1}^{M_{\text{макс}}} P_p(M) \ln \frac{P_p(M)}{P_{ps_2}(M)} = \frac{1}{M_{\text{макс}}} \sum_{M=1}^{M_{\text{макс}}} \ln P_{ps_2}(M) + \frac{\ln M_{\text{макс}}}{M_{\text{макс}}}.$$

Шаг 4. Если $\Delta I_1 > \Delta I_2$, то в качестве окончательного апостериорного распределения принять $P_{ps_2}(M)$, в противном случае – $P_{ps_1}(M)$.

6.3. Литература к главе 6

1. Большаков И.А. Статистические проблемы выделения потока сигналов из шума / И.А. Большаков. М.: Советское радио, 1969. 464 с.

2. Большаков И.А. Прикладная теория случайных потоков / И.А. Большаков, В.С. Ракошиц. М.: Советское радио, 1978. 248 с.

3. Обнаружение пространственно-распределённых целей / Г. Ван дер Спек. Зарубежная радиоэлектроника, №9, 1972. С. 3-16.

4. Сосулин Ю.Г. Теория обнаружения и оценивания стохастических сигналов / Ю.Г. Сосулин. М.: Советское радио, 1978. 320 с.
5. Вопросы статистической теории радиолокации / Г.П. Тартаковский и др. М.: Советское радио, 1963-1964. Т. 1, 1963. 424 с. Т. 2, 1964, 1079 с.
6. Миддлтон Д. Введение в статистическую теорию связи / Д. Миддлтон : пер с англ. Под ред. Б.Р. Левина. Т. 2. М.: Советское радио, 1962. 831 с.
7. Репин В.Г. Статистический синтез при априорной неопределённости и адаптация информационных систем / В.Г. Репин, Г.П. Тартаковский. М.: Советское радио, 1977. 432 с.
8. Сачков В.Н. Вероятностные методы в комбинаторном анализе / В.Н. Сачков. М.: Наука, 1978. 231 с.
9. Кулбак С. Теория информации и статистика / С. Кульбак: пер. с англ. Под ред. А.Н. Колмогорова. М.: Наука, 1967. 408 с.
10. Дьяконов В.П. MATLAB 6.5 SP1/7.0 + SIMULINK 5/6: Основы применения / В.П. Дьяконов. М.: СОЛОН-ПРЕСС, 2005. 800 с.

7. СИНТЕЗ И АНАЛИЗ КВАЗИОПТИМАЛЬНЫХ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ПРЦ

Оптимальная обработка сигналов, отраженных от ПРЦ, как это показано в предыдущей главе, требует больших вычислительных затрат. Сложность реализации оптимальных алгоритмов обнаружения, необходимость задания априорной информации о числе элементов ПРЦ и отношении сигнал/шум, а при отсутствии такой информации, введение в структуру обнаружителей блоков оценивания – все это существенно затрудняет практическое использование оптимальных обнаружителей ПРЦ.

Поэтому естественным является переход к квазиоптимальным алгоритмам обнаружения, в меньшей степени или совсем независимых от априорной неопределенности и наиболее просто реализующихся как на дискретных, так и на аналоговых элементах. Спектр квазиоптимальных алгоритмов чрезвычайно широк. Чтобы ограничить его, в работе рассматриваются алгоритмы, являющиеся асимптотически оптимальными при некоторых граничных условиях, например, при малых ($g \rightarrow 0$) или больших ($g \rightarrow \infty$) отношениях сигнал/шум.

Сравнение квазиоптимальных алгоритмов проводится по характеристикам обнаружения и вычислительным затратам. Аналитические выражения вероятностей правильного обнаружения и ложной тревоги получены для релеевской модели флуктуаций амплитуд отраженных сигналов, поскольку даже в этом наиболее простом случае, у большинства алгоритмов они настолько сложны, что не могут быть использованы для практических расчетов при числе объемов разрешения больше десяти-пятнадцати. Для сравнения квазиоптимальных алгоритмов в широком наборе ситуаций обнаружения применен метод статистического моделирования. При этом с целью экономии машинного времени на основании аналитических выражений для вероятностей ложной тревоги вычисляются точные пороги принятия решения. Затем они подставляются в квазиоптимальный алгоритм, на входе которого моделируются в виде случайного процесса принятый сигнал на фоне

шума, а на выходе – решение о наличии или отсутствии ПРЦ. При этом следует отметить, что выводы, сделанные на основе анализа алгоритмов обнаружения при релейской модели, не только по качественным, но в значительной степени по количественным параметрам, остаются справедливыми при других моделях распределений амплитуд и фаз радиолокационных сигналов ПРЦ.

Исследование квазиоптимальных статистик осуществляется отдельно для случая, когда в одном объеме разрешения может быть не более одного элемента (ПРЦ с разрешаемыми элементами), и для более общего случая, когда в одном объеме может быть произвольное число элементов (ПРЦ с неразрешаемыми элементами).

7.1. Квазиоптимальные алгоритмы с дискретным накоплением при большом числе уровней квантования

В разделе рассматриваются квазиоптимальные алгоритмы обнаружения дружно движущейся ПРЦ с разрешаемыми элементами, асимптотически эквивалентные оптимальному при отношении сигнал/шум, стремящемся к нулю. Вследствие большого числа уровней квантования дискретный квазиоптимальный алгоритм является по существу аналоговым. Синтез и анализ проводится в общем случае для произвольных вероятностей P_i наличия элемента ПРЦ в i -м объеме разрешения, а количественные характеристики обсуждаются для важного частного случая – одинаковых P_i .

7.1.1. Неодинаковые P_i

Проведем упрощение оптимального алгоритма при отношении сигнал/шум, стремящемся к нулю ($g \rightarrow 0$), и релейской модели отраженных сигналов. В этом случае экспоненту с достаточной степенью точности можно представить двумя первыми членами ряда Тейлора в окрестности точки $g = 0$:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M (1+g)^{MN}} \sum_{q=1}^{\binom{L}{M}} \left[1 + \frac{g}{1+g} \sum_{i=1}^M \rho_i A_n^2 \left(\frac{y}{\tau_{q_k}} \right) \right], \quad (7.1.1).$$

Упростим это выражение, для чего исключим из него постоянное слагаемое, отнеся его в порог:

$$\Lambda(y) = \sum_{M=1}^{M_{\max}} \frac{gP(M)}{C_M(1+g)^{MN+1}} \sum_{q=1}^{\binom{L}{M}} \sum_{i=1}^M \rho_i \sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{qik}} \right). \quad (7.1.2)$$

Двойная сумма $\sum_{q=1}^{\binom{L}{M}} \sum_{i=1}^M$ содержит всего $M \binom{L}{M}$ слагаемых вида

$x_{q_i} = \rho_i \sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{qik}} \right)$ и симметрична относительно каждого x_{q_i} . Следовательно,

но, имеется равенство:

$$\sum_{q=1}^{\binom{L}{M}} \sum_{i=1}^M x_{q_i} = \binom{L}{M} \frac{M}{L} \sum_{i=1}^L x_i = \binom{L-1}{M-1} \sum_{i=1}^L x_i. \quad (7.1.3)$$

Подставив правую часть (7.1) в (7.2), получим

$$\Lambda_1(y) = \sum_{M=1}^{M_{\max}} \frac{gP(M)}{C_M(1+g)^{MN+1}} \binom{L-1}{M-1} \sum_{i=1}^L x_i = U \sum_{i=1}^L x_i, \quad (7.1.4)$$

где $U = \sum_{M=1}^{M_{\max}} \frac{gP(M)}{C_M(1+g)^{MN+1}} \binom{L-1}{M-1}$.

Итак, без учета постоянного множителя, который может быть отнесен в изменение порога, получившийся квазиоптимальный алгоритм (7.1.4) с весовым накоплением принятых сигналов за все время наблюдения асимптотически эквивалентен при $g \rightarrow 0$ оптимальному алгоритму. Вес ρ_i , $i = \overline{1, L}$, определяется вероятностью P_i , $i = \overline{1, L}$, появления отраженного сигнала в i -м объеме разрешения $\rho_i = \gamma P_i$, где γ – любая константа, например, L . При релейской модели флуктуаций амплитуд отраженных сигналов этот алгоритм соответствует широко используемому квадратичному детектору с весовым линейным интегратором:

$$\Lambda_{10}(y) = \sum_{i=1}^L \rho_i \sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{ik}} \right). \quad (7.1.5)$$

При другой модели отраженных сигналов изменится лишь вид нелинейной операции – логарифма отношения правдоподобия – на входе весового интегратора:

$$\Lambda_{11}(y) = \sum_{i=1}^L \rho_i \sum_{k=1}^N \ln B\left(\frac{y}{\tau_{ik}}\right). \quad (7.1.6)$$

Формирование статистики Λ_{10} можно выполнить на ЭЦВМ с числом разрядов регистров арифметического устройства, большим 20, причем, в случае существенно различающихся ρ_i форма представления числа должна быть плавающей. Число уровней квантования аналого-цифрового преобразователя (АЦП) должно соответствовать числу разрядов регистров. Необходимая машинная память $\Pi_{\Lambda_{10}} = 2L + 1$, машинное время – $T_{\Lambda_{10}} = L(t_{\times} + (N+1)t_{+})$.

Определим зависимость вероятности правильного обнаружения $D = D(L, T, g)$ и ложной тревоги $T = T(L, T)$ от порога принятия решения T и радиолокационных параметров L и g . Для этого найдем вид распределения $f(\Lambda)$ случайной величины Λ_{10} на выходе линейного интегратора после обработки сигналов за N периодов повторения. Поскольку статистика Λ_{10} есть взвешенная сумма случайных величин $\sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{ik}}\right)$, $i = \overline{1, L}$, имеющих хи-квадрат распределение с $2N$ степенями свободы [1], то при отыскании $f(\Lambda)$ можно воспользоваться методом характеристических функций. Характеристическая функция распределения $f(A_n^2)$ имеет вид:

$$\varphi_r(t) = [1 + jt(1 + gr)]^{-1}, \quad r_i \in \{0, 1\}. \quad (7.1.7)$$

В выражении (7.7) $r = 0$ соответствует чисто шумовому отсчету, $r = 1$ – отсчету, являющемуся суммой отраженного сигнала и шума приемника. В этих обозначениях характеристическая функция распределения

статистики $\sum_{k=1}^N A_n^2 \left(\frac{y}{\tau_{ik}}\right)$ равна

$$\varphi_{r_i}^N(t) = [1 + jt(1 + gr_i)]^{-N}, \quad r_i \in \{0, 1\}, i = \overline{1, L}. \quad (7.1.8)$$

Умножение на вес ρ_i несущественно изменяет вид характеристических функций:

$$\varphi_{r_i}^N(t) = [1 + jt\rho_i(1 + gr_i)]^{-N} = [1 + jtw_i]^{-N}. \quad (7.1.9)$$

где $w_i = \rho_i(1 + gr_i)$, $i = \overline{1, L}$.

Предположим, что коэффициенты w_i попарно не равны: $w_i \neq w_k$, $i \neq k$, $i, k = \overline{1, L}$. Тогда характеристическая функция статистики Λ_{10} для одной из ситуаций при заданном числе элементов ПРЦ M соответствует произведению L характеристических функций (7.1.9):

$$\varphi_{\Lambda_{10}, M}(t) = \frac{1}{C_M} \prod_{i=1}^L P_i^{r_i} \varphi_{r_i}^{(N)}(t) = \frac{1}{C_M} \prod_{i=1}^L P_i^{r_i} [1 + jtw_i]^{-N}, \quad (7.1.10)$$

где целые величины r_i удовлетворяют условию $\sum_{i=1}^L r_i = M$, $r_i \in \{0, 1\}$.

Характеристическая функция статистики Λ_{10} , усредненная по всем возможным ситуациям, имеет вид:

$$\varphi_{\Lambda_{10}}(t) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{r_1 + r_2 + \dots + r_L = M} \prod_{i=1}^L P_i^{r_i} [1 + jtw_i]^{-N}. \quad (7.1.11)$$

Вероятность правильного обнаружения D находится интегрированием обратного преобразования Фурье от (7.1.11) в пределах от T до ∞ :

$$D = \int_T^\infty \frac{1}{2\pi} \int_{-\infty}^\infty \varphi_{\Lambda_{10}}(t) e^{jtx} dt dx = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{r_1 + \dots + r_L = M} \prod_{i=1}^L P_i^{r_i} I_L(\vec{w}, \vec{m}, \vec{T}), \quad (7.1.12)$$

где интеграл $I_L(\vec{w}, \vec{m}, T)$ вычислен в [2] в общей форме. Здесь вектор коэффициентов $\vec{w} = [w_1, \dots, w_L]^T$, вектор показателей степени $\vec{m} = [N, N, \dots, N]^T$. Оба вектора имеют размерность L . Итак,

$$D = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{\sum_{i=1}^L r_i = M} \prod_{i=1}^L P_i^{r_i} \frac{(-1)^{LN-N}}{\prod_{i=1}^L w_i^N} \sum_{i=1}^L \sum_{\substack{a_i = N-1 \\ l=0 \\ l \neq i}} w_i^{a_i+1} \frac{T^{a_0}}{a_0!} \times \\ \times \exp\left(-T/w_i\right) \prod_{\substack{l=1 \\ l \neq i}}^L \frac{(a_l + N - 1)!}{a_l!(N-1)!} \left(\frac{1}{w_i} - \frac{1}{w_l}\right)^{-N-a_l}. \quad (7.1.13)$$

Вероятность ложной тревоги F находится по выражению (7.1.13) при подстановке в него значений $P(M) = d(M)$, $M = 0$, $g = 0$, где

$$d(x) = \begin{cases} 1, & 0=x \\ 0, & 0 \neq x \end{cases};$$

$$F = \frac{(-1)^{LN-N}}{\prod_{i=1}^L \rho_i^N} \sum_{i=1}^L \sum_{\sum_{l=0}^i a_l = N-1} \frac{T^{a_0} \rho_i^{a_{i+1}}}{a_0!} e^{-T/\rho_i} \prod_{\substack{l=1, \\ l \neq i}}^L \frac{(N+a_l-1)!}{a_l!(N-1)!} \left(\frac{1}{\rho_i} - \frac{1}{\rho_l} \right)^{-N-a_l}. \quad (7.1.14)$$

В частности, при $N = 1$ формула (7.1.14) существенно упрощается:

$$F = \sum_{i=1}^L \frac{e^{-T/\rho_i}}{\prod_{\substack{l=1 \\ l \neq i}}^L (1 - \rho_i/\rho_l)}. \quad (7.1.15)$$

Вычисление порога T согласно (7.1.15) реализовано в процедуре *FIN*, приведенной в [2].

Использование точных аналитических выражений (7.1.13) и (7.1.14) для расчета характеристик обнаружения наталкивается на большие вычислительные трудности даже при малых значениях L и $M_{\text{макс}}$. Эти трудности обусловлены двумя причинами: ограниченным числом разрядов в представлении чисел на ЭЦВМ (обычно не более 12) и экспоненциально возрастающим количеством ($\sim 2^L$) анализируемых ситуаций. Первая причина приводит к таким большим ошибкам, вторая – к таким затратам машинного времени, что уже при $L > 16$ единственным возможным методом получения характеристик обнаружения на ЭЦВМ является метод статистического моделирования. Для снижения числа испытаний и повышения точности анализа значения порога T определяется по формуле (7.1.14). При разрешении (7.1.14) относительно T используется двойная точность (24 значащих цифры) и метод Ньютона [3].

Если некоторые из коэффициентов w_i попарно равны, то вид выражения (7.1.3) для вероятности правильного обнаружения остается прежним, изменяются лишь параметры интеграла $I_k(\bar{w}, \bar{m}, T)$. Например, при двух одинаковых $\rho_i = \rho_j$, $i \neq j$, $k = L - 1$, $m_i = 2N$, величины m_j и w_j из состава векторов $\bar{m}$ и $\bar{w}$ исключаются.

7.1.2. Одинаковые P_i

Как указывалось в главе 6, такие вероятности назначаются в том случае, когда о распределении вероятностей P_i известно только то, что оно ограничено. Подобный вид априорной неопределенности довольно часто встречается на практике. Статистика обнаружения при релейской модели отраженного сигнала соответствует выражению

$$\Lambda_{12}(y) = \sum_{i=1}^L P_i \sum_{k=1}^N A_{ik}^2 \left(\frac{y}{\tau_{ik}} \right) = \sum_{j=1}^m A_{ij}^2 \left(\frac{y}{\tau_j} \right), \quad (7.1.16)$$

где $m = NL$, индекс j соответствует задержке различных интервалов разрешения и периодов повторения, $j = (k-1)L + i$. При реализации алгоритма (7.16) на универсальных ЭЦВМ необходимая машинная память $\Pi_{\Lambda_{12}} = L+1$ ячеек, то есть почти вдвое меньше, чем при неодинаковых P_i и машинное время $T_{\Lambda_{12}} = LNt_{\text{д}}$, которое также меньше, чем $T_{\Lambda_{10}}$.

Характеристическая функция статистики Λ_{12} при условии, что на входе приемника имеется M сигналов, отраженных от M элементов ПРЦ, записывается в виде

$$\Phi_{\Lambda_{12}, M}(t) = \Phi_0^{L-M}(t) \Phi_1^M(t), \quad (7.1.17)$$

где $\Phi_0(t)$ и $\Phi_1(t)$ определяются выражением (7.1.7).

Вероятность правильного обнаружения равна

$$\begin{aligned} D = \sum_{M=1}^{M_{\text{макс}}} P(M) & \left[\frac{(-1)^{m_2} C^{m_2}}{(m_2-1)!} \exp(-T) \times \right. \\ & \times \sum_{a=0}^{m_1-1} \sum_{b=0}^{m_1-a-1} \frac{(m-a-b-2)!}{a!(m_1-a-b-1)!} T^a (1-C)^{-m+a+b+1} + \frac{(-1)^{m_1} C^{m_2}}{(m_1-1)!} \times \\ & \left. \times \exp(-CT) \sum_{a=0}^{m_2-1} \sum_{b=0}^{m_2-a-1} \frac{(m-a-b-2)!}{a!(m_2-a-b-1)!} T^a C^{-1-b} (1-C)^{-m+a+b+1} \right], \end{aligned} \quad (7.1.18)$$

где $m_1 = N(L-M)$; $m_2 = NM$; $m = m_1 + m_2$; $C = 1/(1+g)$.

Впервые эта формула получена в частном виде в [4]. Выражение в угловых скобках соответствует $I_2(1, 1 + g; m_1, m_2; T)$.

Вероятность ложной тревоги находится подстановкой $C = 1$, $M = 0$, $P(M) = d(M)$ в (7.17) и выражается через неполную гамма-функцию:

$$F = \exp(T) \sum_{a=0}^{m-1} \frac{T^a}{a!} = 1 - \frac{\Gamma(T, m)}{\Gamma(m)}. \quad (7.1.19)$$

Вычисление порога T согласно (7.1.19) следует проводить по одной из процедур *FIN*, *GIN*, приведенных в [2]. Практическое вычисление характеристик обнаружения по (7.1.18) возможно при m_1, m_2 , меньших 20, что также объясняется конечным числом разрядов представления чисел на ЭЦВМ. Однако при больших четных m вероятность правильного обнаружения можно определить либо путем численного интегрирования по формуле [4]

$$D = 1 - 2 \sum_{M=1}^{M_{\max}} P(M) \frac{C^{m_2}}{\pi} (-1)^{m/2} \times \int_0^\infty \frac{\sin \frac{tT}{2} \left(\cos \frac{tT}{2} + m_1 \operatorname{arctg} \frac{1}{t} + m_2 \operatorname{arctg} \frac{C}{t} \right) dt}{t(t^2 + 1)^{m_1/2} (t^2 + C)^{m_2/2}}, \quad (7.1.20)$$

либо по приближенным формулам, полученным в результате разложения плотности вероятности $f(\Lambda_{12})$ в ряды Эджворта [1] или Лагерра [5, 6]. Вычисления статистических характеристик, использующие ряд Эджворта, формализованы в процедуре *FRSH*, а ряд Лагерра – в процедуре *POLLAG*. Обе процедуры приведены в [2]. Семиинварианты, определяющие коэффициенты этих рядов, вычисляются по формуле:

$$L_r = (r - 1)! [m_2 (1 + g)r + m_1]. \quad (7.1.21)$$

Характеристики обнаружения квазиоптимального алгоритма (7.1.16), рассчитанные по точным аналитическим выражениям, показаны на рис. 7.1–7.3. Анализ построенных зависимостей приводит к выводу, что в целом вероятность правильного обнаружения существенно зависит от параметров η и ν априорного распределения числа элементов ПРЦ.

Этот вывод подтверждают графики на рис. 7.4. При малых отношениях сигнал/шум вероятность правильного обнаружения практически инвариантна к η и ν . При средних и больших $\bar{G}$ величина D оказывается наибольшей для многоэлементной ПРЦ. Сравнение оптимального (6.1.24) и квазиоптимального (7.1.16) алгоритмов показывает, что они эквивалентны при числе элементов ПРЦ, равном числу интервалов разрешения ($P(M) = \delta(M - L)$). В этом состоит еще одно достоинство алгоритма с аналоговым накоплением.




Рис. 7.1. Характеристики обнаружения алгоритма (7.1.16) при фиксированном первом параметре априорного распределения:
а - $F = 10^{-4}$; б - $F = 10^{-6}$




Рис. 7.2. Характеристики обнаружения алгоритма (7.1.16) при фиксированном втором параметре:
а - $m = 8$; б - $m = 16$




Рис. 7.3. Характеристики обнаружения алгоритма (7.1.16) при различных параметрах квазигaussianого распределения:
а – $m = 8$; б – $m = 16$




Рис. 7.4. Влияние изменения второго (а) и первого (б) параметров на вероятности правильного обнаружения

На рис. 7.5 представлены зависимости максимально возможной вероятности правильного обнаружения $D_{\max}$ для четырех видов априорного распределения. При построении графиков для заданного отношения сигнал/шум выбиралось максимальное значение D при изменении m от 1 до ∞ и фиксированных прочих параметрах. Как и следовало ожидать, наибольшее $D_{\max}$ имеет многоэлементная ПРЦ. При малых отношениях сигнал/шум влияние априорных распределений на $D_{\max}$ практически незаметно.




Рис. 7.5. Максимально достижимые вероятности правильного обнаружения алгоритма (7.1.16):
а – $F = 10^{-4}$; б – $F = 10^{-6}$

На рис. 7.6 показаны графики зависимостей числа $m_0 = L_0 N_0$, при котором вероятности правильного обнаружения соответствуют наибольшим значениям $D_{\max}$.




Рис. 7.6. Оптимальное число объемов разрешения алгоритма (7.1.16)
в области наблюдения

Имеется существенное отличие в оптимальном числе m_0 для мало-элементной ПРЦ по сравнению с другими видами априорных распределений. При малых отношениях сигнал/шум и $m_0 = 1$ уменьшение уровня ложной тревоги приводит к сдвигу всех зависимостей $D = D(\eta, \nu g)$ вправо по оси G и незначительному изменению их формы и взаимоположения.

На основании графиков на рис. 7.6 при заданном отношении сигнал/шум и известных размерах ПРЦ выбирается оптимальная величина разрешающей способности, являющаяся одним из наиболее важных параметров зондирующего сигнала.

7.2. Квазиоптимальные алгоритмы с дискретным накоплением при малом числе уровней квантования

Вычислительные затраты при формировании квазиоптимальных статистик предыдущего параграфа, обусловленные большим числом уровней квантования, довольно велики. Поэтому актуальным является вопрос: на какое число уровней необходимо квантовать принимаемые сигналы, чтобы величина потерь по пороговому сигналу была не больше заданной. Ответ на этот вопрос в отношении квазиоптимальных алгоритмов с накоплением для обнаружения ПРЦ со случайным числом элементов дает настоящий раздел.

7.2.1. Неодинаковые P_i

Допустим, что каждый разряд на выходе АЦП соответствует целой степени 2. Общее число уровней квантования АЦП обозначим R , число разрядов $B = [\log_2 R] + 1$. Следовательно, минимальное число, отличное от нуля, равно единице, максимальное – 2^{B-1} , динамический диапазон – $6,02(B - 1)$ дБ по напряжению. Введем вектор $\vec{h} = [h_0, h_1, \dots, h_R]^T$ уровней квантования. В общем случае $h_0 \neq 0$. Целочисленная квазиоптимальная статистика находится по следующему алгоритму, записываемому на основании аналогового алгоритма (7.1.5):

$$\Lambda_{20}(y) = \sum_{i=1}^L \rho_i \sum_{k=1}^N \sum_{r=0}^R r \left\{ 1[x_{ik} - h_r] - 1[x_{ik} - h_{r-1}] \right\}, \quad (7.2.1)$$

где $1[x] = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0 \end{cases}$ – единичная функция;

ρ_i – целые весовые коэффициенты, соответствующие вероятностям наличия отраженных сигналов в i -м элементе разрешения; $x_{ik} = A_n^2 \left(\frac{y}{\tau_{ik}} \right)$.

При реализации алгоритма (7.2.1) необходимо провести $L \cdot N$ квантований нормированной амплитуды x_i и выполнить $L(N + 1)$ умножений и L сложений R -значных чисел: $T_{\Lambda_{20}} = L(N + 1)t_{R_+} + Lt_{R_-} + Lnt_{\text{кв}}$. Требуемая машинная память составляет $\Pi_{\Lambda_{20}} = 2L + 1$ ячеек, предназначенных для хранения R -значных чисел.

Характеристики обнаружения алгоритма (7.2.1.) находятся методом производящих функций. Определим вид производящей функции статистики Λ_{20} в одном периоде повторения. Отсчёт на выходе АЦП в некотором интервале разрешения может соответствовать либо шуму, либо шуму + сигналу. Вероятность появления отсчёта, равного r , $r = \overline{0, R - 1}$, в первом случае обозначим $\mu_0(r)$, во втором случае – $\mu_1(r)$.

Эти вероятности определяются соотношениями

$$\mu_s(r) = \int_{h_r}^{h_{r+1}} f_s(x) dx, \quad s \in \{0, 1\}; \quad h_{R+1} = \infty, \quad (7.2.2)$$

где $f_s(x)$, $s \in \{0, 1\}$ – плотности распределения случайной величины $A_n^2\left(\frac{y}{\tau_{ik}}\right)$ на входе АЦП при отсутствии и наличии отраженного сигнала.

При релеевской модели отраженных сигналов и условии, что они разрешены, эти величины равны

$$\mu_s(r) = e^{-h_r/(1+sg)} - e^{-h_{r+1}/(1+sg)}, \quad s \in \{0, 1\}. \quad (7.2.3.)$$

Производящая функция ψ_s целочисленной величины y на выходе АЦП строится на основании вероятностей $\mu_s(r)$ [7]:

$$\psi_s(y) = \sum_{r=0}^{R-1} \mu_s(r) y^r, \quad s \in \{0, 1\}. \quad (7.2.4)$$

Очевидно, при умножении y на целый весовой коэффициент ρ производящая функция новой величины $z = \rho y$ полностью определяется выражением (7.2.4):

$$\psi_s\left(\frac{z}{\rho}\right) = \sum_{r=0}^{R-1} \mu_s(r) z^r, \quad s \in \{0, 1\}. \quad (7.2.5)$$

Это выражение можно записать относительно всех $z = \overline{0, (R-1)\rho}$, если доопределить $\mu_s(r)$ при нецелых r равными нулю:

$$\psi_s(z) = \sum_{r=0}^{\rho(R-1)} \mu_s\left(\frac{r}{\rho}\right) z^r, \quad s \in \{0, 1\}. \quad (7.2.6)$$

Тогда производящая функция $\psi_{\Lambda_{20}, M}$ при наличии M отраженных сигналов имеет вид:

$$\psi_{\Lambda_{20}, M}(z) = C_M^{-1} \sum_{l_1 + l_2 + \dots + l_L = M} \prod_{i=1}^L P_i^{l_i} \psi_{l_i}(z), \quad l_i \in \{0, 1\}, \quad (7.2.7)$$

где $\psi_{l_i}(z) = \sum_{r=0}^{\rho_i(R-1)} \mu_{l_i}\left(\frac{r}{\rho_i}\right) z^r$.

Производящая функция $\psi_{\Lambda_{20}}(z)$ статистики Λ_{20} за все время наблюдения, усредненная по случайному числу элементов ПРЦ, легко находится по формуле (7.2.7):

$$\psi_{\Lambda_{20}}(z) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{l_1 + l_2 + \dots + l_L = M} \prod_{i=1}^L P_i^{l_i} \psi_{l_i}^N(z), \quad l_i \in \{0, 1\}. \quad (7.2.8)$$

Переходя от производящей функции (7.2.8) к распределению вероятности $P(\Lambda_{20})$ и суммируя его в пределах от целочисленного порога T до $LN(R-1)$, получим вероятность правильного обнаружения алгоритмом (7.2.1) дружно движущейся ПРЦ с разрешаемыми элементами:

$$D = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{l_1 + l_2 + \dots + l_L = M} \prod_{i=1}^L P_i^{l_i} \sum_K (\bar{R}, \bar{\mu}(\bar{r}), \bar{n}, T), \quad (7.2.9)$$

где $\sum_K (\bar{R}, \bar{\mu}(\bar{r}), \bar{n}, T)$ – вычисленная в [2] сумма от обратного

Z-преобразования производящей функции $\psi(z) = \prod_{i=1}^K \left(\sum_{r=0}^{R_i} \mu_i(r) z^r \right)^{n_i}$

в пределах от T до $\sum_{i=1}^K (R_i - 1)n_i$. В формуле (7.2.9) $K = L$; $R_i = (R - 1)\rho_i$;

$$\mu_i(r) = \mu_{l_i}\left(\frac{r}{\rho_i}\right); \quad n_i = N, \quad i = \overline{1, L}.$$

Таким образом, вероятность правильного обнаружения D определяется по формуле

$$D = (N!)^{(R-1)L} \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{b=T}^{N(R-1)\sum_{i=1}^L \rho_i} \sum_{\substack{l_i=M \\ l_i \in \{0,1\}}}^L \sum_{\substack{r=0 \\ \sum_{i=1}^L \sum_{r=0}^{R-1} \rho_i r \alpha_{r_i} = b}}^{R-1} \prod_{i=1}^L P_i^{l_i} \prod_{r=0}^{R-1} \frac{(\mu_{l_i}(r))^{\alpha_{r_i}}}{\alpha_{r_i}!}, \quad (7.2.10)$$

где оба последних произведения выполняются по всем совместным решениям в целых числах двух подстрочных уравнений.

Вероятность ложной тревоги находится с помощью подстановки в (7.31) условий $M = 0$, $P(M) = d(M)$, $g = 0$:

$$F = \sum_K (\bar{R}, \bar{\mu}(\vec{r}), \vec{n}, T) = (N)^{(R-1)L} \sum_{b=T}^{N(R-1)\sum_{i=1}^L \rho_i} \sum_{\substack{r=0 \\ \sum_{i=1}^L \sum_{r=0}^{R-1} \rho_i r \alpha_{r_i} = b}}^{R-1} \prod_{i=1}^L \prod_{r=0}^{R-1} \frac{\mu_0^{\alpha_{r_i}}(r)}{\alpha_{r_i}!}, \quad (7.2.11)$$

где $\mu_0(r)$ находится из (7.2.3) при $s = 0$;

$$R_i = (R-1)\rho_i; \quad \mu_i(r) = \mu_0\left(\frac{r}{\rho_i}\right); \quad n_i = N, \quad i = \overline{1, L}.$$

Практически расчет характеристик обнаружения по формулам (7.2.10) и (7.2.11) возможен при $LNR < 30-40$. Если произведение LNR превышает эту границу, то необходимо обратиться к приближенным методам – статистическому моделированию или разложению распределений в ряды Эджворта [1] и Грама-Шарлье [8]. В последнем случае затраты машинного времени уменьшаются несущественно, так как вместо $\sum_K (\bar{R}, \bar{\mu}(\vec{r}), \vec{n}, T)$ в (7.2.10) требуется вычислить сумму семиинвариантов для L производящих функций. Эти семиинварианты находятся по формулам, приведенным в [9,10]. Вычисления проводятся в начале работы программы, количество ячеек на хранение j семиинвариантов каждой производящей функции равно $2jL$. Переход от семиинвариантов к вероятностям и наоборот может быть выполнен с помощью процедуры *FRSH* [2].

Приведем выражения характеристик обнаружения для важного частного случая, когда число уровней квантования равно двум ($R = 2$).

Этот случай соответствует наиболее простому – бинарному – квантованию принимаемого сигнала. Вероятность правильного обнаружения согласно (7.2.11) при $R = 2$ равна:

$$D = (N!)^L \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{\substack{L_i=M \\ \sum_{i=1}^L l_i=0,1}} \sum_{\substack{b=T \\ \sum_{i=1}^L \rho_i (N-\alpha_i)=b}} \sum_{i=1}^L P_i^{l_i} \frac{\mu_{l_i}^{\alpha_i}(0) (1-\mu_{l_i}(0))^{N-\alpha_i}}{\alpha_i! (N-\alpha_i)!},$$

где $\mu_{l_i}(0) = \int_{b_0}^{b_1} f_{l_i}(x) dx$, $l_i \in \{0, 1\}$; $l_i = 0$ соответствует шуму, $l_i = 1$ – шуму + сигналу; $f_0(x), f_1(x)$ – соответствующие плотности распределений случайного процесса на входе АЦП. В частности, если $N = 1$, то

$$D = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{b=T}^{\sum P_i} \sum_{\substack{L_i=M \\ \sum_{i=1}^L l_i=M \\ \alpha_i \in \{0,1\}}} \sum_{i=1}^L P_i^{l_i} [\mu_{l_i}(0)]^{1-\alpha_i} [1-\mu_{l_i}(0)]^{\alpha_i}. \quad (7.2.12)$$

Вероятность ложной тревоги находится подстановкой в (7.1.33) $M = 0$, $g = 0$, $P(M) = d(M)$:

$$F = (N!)^L \sum_{b=T}^{N \sum P_i} \sum_{\substack{L_i=b \\ \sum_{i=1}^L \alpha_i=b}} \prod_{i=1}^L \frac{\mu_0^{N-\alpha_i} (1-\mu_0)^{\alpha_i}}{(N-\alpha_i)! \alpha_i!}. \quad (7.2.13)$$

При $N = 1$ она равна

$$F = \sum_{b=T}^{N \sum P_i} \sum_{\substack{L_i=b \\ \sum_{i=1}^L \alpha_i=b}} \prod_{i=1}^L \mu_0^{1-\alpha_i} (1-\mu_0)^{\alpha_i}, \quad \alpha_i = \overline{0, b}. \quad (7.2.14)$$

Количество слагаемых в формуле (7.2.14), определяемое выражением $\sum_{b=T}^{LN} V_L(b) = \sum_{b=T}^{LN} \binom{L+b-1}{b}$, резко возрастает с увеличением LN (скорость

роста превышает экспоненциальную). При $N = 1$ количество слагаемых, равное $\sum_{b=\bar{r}}^L \binom{L}{b}$, увеличивается не быстрее, чем 2^{L-1} . Эти оценки скорости роста справедливы при больших вероятностях ложных тревог ($F > 0,1$) При $F \ll 0,1$ и $R \leq 8$ количество слагаемых в обоих уравнениях с увеличением L и N возрастает почти по линейному закону.

7.2.2. Одинаковые P_i

В этом случае целочисленная статистика обнаружения находится по алгоритму простого (невзвешенного) суммирования:

$$\Lambda_{21} = \sum_{i=1}^L \sum_{k=1}^N \sum_{r=0}^{R-1} r \{1[x - h_r] - 1[x - h_{r+1}]\}, \quad (7.2.15)$$

где все обозначения аналогичны обозначениям, применявшимся при записи алгоритма Λ_{20} в пункте 7.2.1. Очевидно, что характеристики обнаружения алгоритма (7.2.15) могут быть найдены по формулам предыдущего пункта при условии, что все P_i одинаковы и равны $1/L$: $\sum_{i=1}^L P_i = 1$. Машинное время и память при формировании статистики Λ_{21} меньше, чем в предыдущем случае:

$$T_{\Lambda_{21}} = LN(t_{R_+} + t_{kb}), \quad \Pi_{\Lambda_{21}} = L + 1.$$

Вероятность правильного обнаружения равна

$$D = (N!)^{L(R-1)} \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M L^M} \sum_{b=\bar{r}}^{LN(R-1)} \sum_{\substack{i=1 \\ l_i \in \{0,1\}}}^L \sum_{\substack{r=0 \\ \sum_{i=1}^{L-1} r a_{ri} = b}}^{R-1} \prod_{i=1}^L \prod_{r=0}^{R-1} \frac{\mu_{l_i}^{\alpha_{r_i}}(r)}{\alpha_{r_i}!}, \quad (7.2.16)$$

где величины $\mu_{l_i}(r)$, $l_i \in \{0, 1\}$ рассчитываются по формуле (7.2.3).

Вероятность ложной тревоги находится по формуле (7.2.17) при условии, что $P(M) = d(M)$; $M = 0$; $g = 0$:

$$\begin{aligned}
 F &= (N!)^{L(R-1)} \sum_{b=T}^{LN(R-1)} \sum_{\substack{\sum_{i=0}^{R-1} a_{ri} = N \\ \sum_{i=1}^{L-1} \sum_{r=0}^{R-1} r a_{ri} = b}} \prod_{i=1}^L \prod_{r=0}^{R-1} \frac{\mu_0^{\alpha_{ri}}(r)}{\alpha_{ri}!} = \\
 &= [(LN)!]^{R-1} \sum_{b=T}^{LN(R-1)} \sum_{\substack{\sum_{r=0}^{R-1} a_r = NL \\ \sum_{r=0}^{R-1} r a_r = b}} \prod_{r=0}^{R-1} \frac{\mu_0^{\alpha_r}(r)}{\alpha_r!}.
 \end{aligned} \tag{7.2.17}$$

В [2] приведены процедуры *DSC4IN* и *DSC8IN*, используя которые можно найти величину порога T соответственно при $R = 4$ и $R = 8$ для заданной вероятности F .

Приведем также формулы для расчета характеристик обнаружения в важном случае бинарного квантования ($R = 2$) принятого сигнала:

$$D = (N!)^L \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M L^M} \sum_{b=T}^{LN} \sum_{\substack{\sum_{i=1}^L l_i = M \\ \sum_{i=1}^L a_i = b \\ l_i \in \{0,1\} \ a_i = \overline{N}}} \prod_{i=1}^L \frac{\mu_{l_i}^{\alpha_i}(1) \mu_{l_i}^{N-\alpha_i}(0)}{\alpha_i! (N-\alpha_i)!}, \tag{7.3}$$

$$F = (N!)^L \sum_{b=T}^{LN} \sum_{\substack{\sum_{i=1}^L a_i = b \\ a_i = \overline{N}}} \prod_{i=1}^L \frac{\mu_0^{\alpha_i}(1) \mu_0^{N-\alpha_i}(0)}{\alpha_i! (N-\alpha_i)!} = \sum_{b=T}^{LN} \binom{LN}{b} \mu_0^b(1) [1 - \mu_0(1)]^{LN-b}. \tag{7.2.18}$$

При выводе (7.2.18) использовано равенство $\sum_{\alpha_1 + \dots + \alpha_L = b} \prod_{i=1}^L \binom{N}{\alpha_i} = \binom{NL}{b}$,

доказанное в [11]. В [2] приведена процедура *CIN*, с помощью которой в зависимости от F и $\mu_0(1)$ определяется целочисленный порог T или вероятность $\mu_0(1)$ в зависимости F и T . Для приближенного

вычисления вероятности ложной тревоги можно воспользоваться пуассоновским приближением биномиального распределения на его правом «хвосте», т. е.

$$F \approx 1 - \frac{\Gamma(a, T)}{\Gamma(a)}, \quad (7.2.19)$$

где $a = m_0 \mu_0(1)$.

Более сложным является определение F методом «перекошенных распределений вероятностей» [12] (модифицированных границ Чернова [13]), для которого необходимо знать кумулятивную функцию. Поскольку семинварианты биномиального распределения имеют вид

$$\aleph_r^{(s)} = \sum_{\alpha=1}^r \frac{(-1)^{\alpha+1}}{\alpha} \mu_s^\alpha(1) \sum_{b=0}^{\alpha} (-1)^{\alpha-b} \binom{\alpha}{b} b^r, \quad s \in \{0, 1\}, \quad r = \overline{1, \infty}, \quad (7.2.20)$$

то семинварианты статистики Λ_{21} при отсутствии отраженных сигналов равны $z_r^{(0)} = m \aleph_r^{(0)}$. Кумулятивная функция биномиального распределения записывается в виде ряда

$$\psi(z) = \sum_{r=1}^{\infty} \frac{Z_r^{(s)}}{r!} z^r, \quad s \in \{0, 1\}. \quad (7.2.21)$$

Полное исследование квазиоптимального алгоритма с бинарным квантователем и линейным сумматором проведено в [10]. Вероятность правильного обнаружения определялась согласно формуле, которая является эквивалентной записью (7.2.19):

$$D = \sum_{M=1}^{M_{\text{max}}} P(M) \sum_{b=T}^{LN} \sum_{\alpha=0}^C \binom{c_1}{\alpha} \binom{c_2}{c_3 - \alpha} \alpha^a \beta^{c_3 - \alpha} (1 - \alpha)^{c_1 - \alpha} (1 - \beta)^{c_2 - c_3 + \alpha}, \quad (7.2.22)$$

где при $m_2 > b$

$$c = \begin{cases} b, & m_1 > b, \\ m_1, & m_1 \leq b, \end{cases} \quad c_1 = m_1; \quad c_2 = m_2; \quad c_3 = b; \quad \alpha = \mu_1(1); \quad \beta = \mu_0(1);$$

при $m_2 \leq b; m_1 < b$

$$c = m - b; \quad c_1 = m_2; \quad c_2 = m_1; \quad c_3 = m - b; \quad \alpha = 1 - \mu_1(1); \quad \beta = 1 - \mu_0(1);$$

при $m_2 \leq b; m_1 > b$

$$c = c_1 = m_2; \quad c_2 = m_1; \quad c_3 = b; \quad \alpha = \mu_1(1); \quad \beta = \mu_0(1).$$

Здесь $m = NL$; $m_1 = (L - M)N$; $m_2 = MN$. Метод «перекошенных вероятностей» может быть использован и для приближенного вычисления вероятностей правильного обнаружения при условии, что в (7.2.22) семинварианты $Z_r^{(1)} = m_2 \mathcal{N}_r^{(1)} + m_1 \mathcal{N}_r^{(0)}$. Более простой путь состоит в использовании $Z_r^{(1)}$ при обращении к рядам Эджворта и Грама-Шарлье.

Характеристики обнаружения алгоритма (7.2.18) при $R = 2$, и различных порогах T приведены на рис. 7.7–7.8.




Рис. 7.7. Характеристики обнаружения алгоритма (7.2.18) при фиксированном втором параметре априорного распределения:
а – $m = 8$; б – $m = 16$




Рис. 7.8. Характеристики обнаружения алгоритма (7.2.18) при различных квазигaussianов априорных распределениях

Графики показывают, что алгоритм с бинарным квантователем в целом существенно хуже обнаруживает ПРЦ, чем алгоритм (7.1.16). На графиках наблюдается резкая зависимость от величины порога T , при уменьшении которого вероятность правильного обнаружения падает, а её зависимость от параметра ν возрастает. Особенно наглядно последняя связь проявляется при сравнении рис. 7.9, а и 7.10.




Рис. 7.9. Влияние изменения второго (а) и первого (б) параметров априорного распределения на вероятности правильного обнаружения




Рис. 7.10. Влияние изменения первого и второго параметров априорного распределения на вероятности правильного обнаружения

Зависимость вероятности правильного обнаружения от параметра η при малых и средних $\bar{G}$ слабая (рис. 7.9, б), при больших $\bar{G}$ возрастание η приводит к резкому увеличению вероятности правильного обнаружения. Влияние изменения параметра η в зависимости от m при различных отношениях сигнал/шум и $\nu = 1$ показано на рис. 7.11. При малых $\bar{G}$ характеристики для $\eta = 1$ и $\eta = 10$ близки во всем диапазоне изменений m , при средних и больших значениях $\bar{G}$ появляется существенная зависимость D от значений η и m .




Рис. 7.11. Зависимости вероятности правильного обнаружения от числа объемов разрешения

Все графики на рис. 7.7–7.8 имеют характерную форму, становясь при больших $\bar{G}$ практически горизонтальными. Действительно, алгоритм (7.2.8) имеет характеристики обнаружения, не стремящиеся при $\bar{G} \rightarrow \infty$ к единице. Покажем это.

При $\bar{G} \rightarrow \infty$ ($g \rightarrow \infty$) значение $\mu_1(1) \rightarrow 1$. Подставив $\mu_1(1) = 1$ в (7.2.23), получим вероятность правильного обнаружения при бесконечно большой мощности отраженного сигнала:

$$D_\infty = \sum_{M=1}^{M_{\max}} P(M) D_M \neq 1, \quad T > 1, \quad (7.2.24)$$

где

$$D_M = \begin{cases} 1, & T \leq m_2, \\ \sum_{\alpha=T-m_2}^{m_1} \binom{m_1}{\alpha} \mu_0^\alpha(1) (1-\mu_0(1))^{m_1-\alpha}, & T > m_2. \end{cases} \quad (7.2.25)$$

Равенство $D_\infty = 1$ выполняется лишь при $T = 1$, возможное при $\mu_1(1) \leq 1 - (1 - F)^{1/m}$. Заметим, что этот вывод справедлив при любых распределениях амплитуд сигнальных отсчетов. Зависимости D_∞ от параметров априорного распределения показаны на рис. 7.12 и 7.13. Увеличение параметра η приводит к возрастанию, а увеличение параметра ν – к уменьшению D_∞ . На рис. 7.14 приведены зависимости D_∞ от порога квантования, т.е. от $\mu_0(1)$. Слева кривые стремятся к единице, а справа – к асимптотам, определяемым выражением (7.2.25) при условии, что $D_M = \begin{cases} 1, & T \leq m_2, \\ 0, & T > m_2. \end{cases}$ Левое граничное значение $\mu_0 = 1$ определяется из заданного порога квантования и вероятности ложной тревоги и равно $F^{1/m}$, поэтому максимальное при данных параметрах значение обнаружения D_∞ определяется согласно (7.2.25) при подстановке в (7.1.47) $\mu_0(1) = \mu_0(1)_{\max} = F^{1/m}$.




Рис. 7.12. Максимальные вероятности правильного обнаружения алгоритма (7.2.16):
а – $m = 8$, $T = 4$; б – $m = 16$, $T = 8$




Рис. 7.13. Максимальные вероятности правильного обнаружения D_∞ алгоритма (7.2.16)




Рис. 7.14. Максимальные вероятности правильного обнаружения алгоритма (7.2.16) при различных порогах квантования

Исследуем зависимости вероятности правильного обнаружения $D(T)$ от порога T , показанные на рис. 7.15 и 7.16. Все графики показывают, в основном, уменьшение D при увеличении T . Лишь при малых и средних отношениях сигнал/шум имеется такое значение T_0 , при котором величина D – наибольшая для данной ситуации обнаружения. Увеличение параметра η приводит к увеличению наилучшего порога T_0 при всех $\bar{C}$, действие ν на выбор T противоположно.




Рис. 7.15. Зависимости вероятностей правильного обнаружения алгоритма (7.2.16) от порога принятия решения




Рис. 7.16. Зависимости вероятности правильного обнаружения алгоритма (7.2.16) от порога принятия решения

Представленные на рис. 7.17 и 7.18 графики являются усредненными вероятностями правильного обнаружения $\bar{D}$, как это показано на рис. 7.17, б. Цифры у изломов означают порог T , который может изменяться только дискретно. Увеличение порога квантования h_1 (уменьшение $\mu_0(1)$) приводит к плавному изменению всех членов суммы в (7.2.23), а соответствующее изменению $\mu_0(1)$ дискретное уменьшение порога T — к появлению новых членов в этой сумме, т.е. разрыву зависимости $D(\mu_0(1))$. Уменьшение $\mu_0(1)$ при больших $\bar{G}$ приводит к увеличению вероятности правильного обнаружения. При $\mu_0(1) < 1 - (1 - F)^{1/m}$ она начинает падать, что говорит о наличии глобального максимума кривых $D(\mu_0(1))$.

При малых $\bar{G}$ имеется локальный максимум вблизи $\mu_0(1) = 0,2$, что совпадает с известным результатам [14]. Графики на рис. 7.18 показывают различный характер зависимостей вероятности D от параметров априорного распределения числа целых.




Рис. 7.17. Усредненные вероятности правильного обнаружения в зависимости от вероятности квантования шума:
а – равномерное распределение; б – многоэлементные ПРЦ




Рис. 7.18. Усредненные вероятности правильного обнаружения в зависимости от вероятности квантования шума:
а – малоэлементные ПРЦ; б – ПРЦ с квазигaussianовым распределением

На рис. 7.19 представлены графики зависимостей m_0 от отношения сигнал/шум. Сравнение их с аналогичными графиками алгоритма (7.2.16) приводит к выводу, что в данном случае m_0 значительно больше, чем у алгоритма (7.2.16). Наблюдается также сильная зависимость оптимального числа объёмов разрешения от вероятности ложной тревоги.




Рис. 7.19. Оптимальное число объёмов разрешения
в области наблюдения алгоритма (7.2.16):
а – $F = 10^{-4}$; б – $F = 10^{-6}$

Численные характеристики обнаружения алгоритма с дискретным накоплением при числе уровней квантования $R = 4, 8, 16$ получены методом статистического моделирования. Число испытаний Q равнялось 1000, для $D = 0,999$ доверительный интервал при уровне значимости 95 % равен 0,002. В действительности он будет несколько меньше (0,0015), так как при таких значениях D более справедлива пуассонова аппроксимация биномиального распределения [60]. Реальные отклонения, как правило, значительно меньше (в 2–4 раза).

Таким образом, точность статистического моделирования при 1000 испытаний удовлетворительна и сравнима с точностью графического изображения характеристик обнаружения. Этот вывод относится ко всем моделируемым квазиоптимальным алгоритмам обнаружения для вероятностей в диапазоне $0,05 \leq D_{\text{экс}} \leq 0,995$ [2].

На рис. 7.20 изображены характеристики обнаружения для случаев многоэлементной и малоэлементной ПРЦ. Анализ характеристик показывает, что во втором случае наилучшим является бинарный квантователь. При $D \geq 0,9$ выигрыш в пороговом сигнале по сравнению с другими малоуровневыми сумматорами ($R = 4, 8, 16$) может достигать больших значений (15 дБ), причем с ростом g этот выигрыш возрастает. Потери по сравнению с аналоговым на уровне $D = 0,9$ составляют 2,5 дБ. При иных типах распределений ПРЦ алгоритм (7.2.16) имеет лучшие характеристики для $R > 2$. Например, выигрыш в пороговом сигнале на уровне $D = 0,9$ и $R = 16$ равен 2,2 дБ и с ростом g уменьшается. Увеличение числа уровней квантования с двух до четырех приводит к резкому изменению характеристик обнаружения, при дальнейшем увеличении R это изменение менее заметно. При обнаружении многоэлементных целей кривые для $R = 16$ практически совпадают с таковыми алгоритма с аналоговым накоплением (7.16).




Рис. 7.20. Характеристики обнаружения алгоритма (7.2.16) при различном числе уровней квантования

Итак, бинарное квантование является наилучшим при обнаружении малозлементной ПРЦ. Для обнаружения ПРЦ с иными видами априорных распределений следует использовать квантование на большее число уровней. Максимальное число уровней квантования равно 16. Дальнейшее увеличение не приводит к заметному улучшению качества обнаружения. С учетом затрат на реализацию наиболее приемлемым следует считать 4–8 уровней.

Одной из задач анализа алгоритма (7.1.37) являлось изучение влияния уровней (порогов) квантования h_r , $r = 1, R-1$ на характеристики обнаружения. В качестве примера на рис. 7.21 приведены зависимости D для двух типов формирования порогов: первом, при котором $h_{R-1} = 4,61$ и равностоящих порогах, и втором, при котором вероятности $\mu_0(r)$, $r = \overline{0, R-1}$, одинаковы и равны $1/R$. Выигрыш за счет применения первого типа порогов очень большой – от 5 дБ до 20 дБ. Хотя с ростом числа уровней квантования этот выигрыш уменьшается, однако во всех рассмотренных ситуациях он остается существенным. Результаты анализа показали, что чем больше число уровней квантования, тем более одинаковыми должны быть расстояния между порогами.




Рис. 7.21. Характеристики обнаружения алгоритма (7.2.16) при двух типах формирования порогов квантования

При этом верхний порог квантования h_{R-1} должен быть не меньше величины $m = -\ln F$. Чем больше второй параметр априорного распределения, тем больше должен быть порог h_{R-1} . В частности, для обнаружения малоэлементной цели следует принять $h_{R-1} = (2-3)m$. При бинарном квантовании порог определяется на основании приведенных выше в настоящем пункте результатов. Промежуточные случаи требуют более детального исследования с использованием оптимизационных методов, например, метода нелинейного программирования.

7.3. Квазиоптимальные алгоритмы с выбором максимума

Рассмотренные в данном параграфе два квазиоптимальных алгоритма с выбором максимума появляются при упрощении оптимального алгоритма при $g \rightarrow \infty$. Упрощение проводится при условии, что обнаруживается малоэлементная ПРЦ, т. е. для априорного распределения числа элементов $P(M) = I_{M/M_{\max}} = (\eta, \nu)$ выполняется неравенство $\eta/(\eta + \nu) \ll 1$.

Этот типичный случай в радиолокационном обнаружении ПРЦ, когда на больших дальностях большеразмерный объект воспринимается как одиночная компактная цель, имеющая заметную эффективную поверхность рассеяния. Подобная ситуация характерна в начальный период обзора сектора ответственности РЛС.

7.3.1. Квазиоптимальный алгоритм с полным выбором максимума

При малом числе элементов ПРЦ ($\overline{M} \ll L$) и увеличении отношения сигнал/шум в оптимальной статистике основную роль будет играть максимальный из всех принятых отсчетов. Особенно это проявляется, когда ПРЦ состоит из одного элемента.

В качестве иллюстрации исследуем соотношения между квазиоптимальным алгоритмом выбора максимума и оптимальным алгоритмом для простого случая, при котором число элементов ПРЦ равно единице, а число интервалов разрешения, приходящихся на ПРЦ равно 2, то есть $L = 2$, $M = 1$. Как шум, так и сигнал + шум имеют релеевское распределение амплитуд: на выходе квадратичного детектора

дискретные отсчеты

$$x_j = \frac{g}{1 + g A_H^2 \left(\frac{y}{\tau_{ik}} \right)}, \quad i = \overline{1, L}, \quad k = \overline{1, N}$$

распределены по экспоненциальному закону. Оптимальная статистика Λ_0 находится в соответствии с алгоритмом

$$\Lambda_0 = \exp(x_1) + \exp(x_2), \quad (7.3.1)$$

квазиоптимальная статистика

$$\Lambda_{\text{кв}} = \max(x_1, x_2). \quad (7.3.2)$$

Вывод формулы для вероятности ложной тревоги алгоритма (7.3.1) приведен в [2] для целых величин $k = 1 + (1 + g)/g$:

$$\begin{aligned} F_0 = & 2(k-1)^2 \sum_{i=1}^{k-1} \binom{k+i-2}{i-1} \left\{ \frac{T^{-k-i+2}}{(k-i)(k+i-2)} - \frac{(-1)^{k-i}}{k-i} \times \right. \\ & \times \left[\sum_{j=1}^{k+i-2} \binom{k-i+j-2}{j-1} \frac{T^{-k-i+j+1}}{k+i-j-1} + \sum_{j=1}^{k-i-1} (-1)^{k-i+j-1} \binom{k+i+j-3}{j-1} \right] \times \\ & \times \frac{T^{-k+i+j}}{k-i-j} - \left(\frac{2k-3}{k+i-2} \right) \ln \frac{T-1}{T} \left. \right\} + (k-1) \binom{2k-2}{k-1} \times \\ & \times \left[\frac{\ln(T-1)}{T^{2k-2}} \sum_{j=1}^{2k-3} \frac{T^{-2k+j+2}}{2k-j-2} + \ln \frac{T-1}{T} \right]. \end{aligned} \quad (7.3.3)$$

Вероятность правильного обнаружения в этой простой ситуации выражается ещё более сложной зависимостью. Вероятность ложной тревоги F_k и правильного обнаружения D_k алгоритма (7.1.49) определяются простыми соотношениями:

$$F_k = 1 - \left(1 - \exp\left(-\frac{gT}{1+g}\right) \right)^2; \quad D_k = 1 - \left(1 - \exp\left(-\frac{gT}{1+g}\right) \right) (1 - \exp(gT)). \quad (7.3.4)$$

Проведено сравнение для интересующего нас случая большого отношения сигнал/шум ($g \rightarrow \infty$). Выбор максимума в этом случае будет представлять собой практически оптимальный алгоритм. Сопоставление характеристик обнаружения приводит к выводу, что оба алгоритма эквивалентны при $g > 15$ дБ и $F < 0,1$, при $g < 15$ дБ алгоритм (7.3.1) имеет существенное превышение, отчетливо проявляющееся только при $F > 0,1$.

Неодинаковые P_i . В этом случае при указанных в начале раздела условиях и релеевской модели отраженного сигнала оптимальный алгоритм сводится к полному выбору максимума взвешенных отсчетов:

$$\Lambda_{30} = \max_{\substack{i=1, L \\ k=1, N}} \left\{ \rho_i A_n^2 \left(\frac{y}{\tau_{ik}} \right) \right\}, \quad (7.3.5)$$

где ρ_i – вес соответствующий вероятности P_i .

Этот алгоритм эквивалентен алгоритму, состоящему в принятии решения о наличии цели при превышении порога хотя бы одним из значений $\rho_i A_n^2 \left(\frac{y}{\tau_{ik}} \right)$. Операция сравнения с порогом сравнительно просто реализуется на ЭЦВМ, время ее выполнения в среднем на порядок меньше, чем любой арифметической операции. Например, время на реализацию алгоритма (7.3.5) равно $T_{\Lambda_{30}} = LN(t_{\text{кв}} + t_{\leq})$, а для хранения информации необходима память $L + 1$ ячеек. Второе достоинство этого алгоритма состоит в том, что помимо факта обнаружения, с его помощью можно грубо оценить координаты обнаруживаемого объекта. Недостатком является неполный учет априорной информации о характере движения ПРЦ, поэтому он несколько уступает квазиоптимальному алгоритму с накоплением и выбором максимума, обсуждаемому ниже.

Характеристики обнаружения алгоритма (7.3.5) определяются с использованием обычных методов теории вероятностей [7]. Вероятность правильного обнаружения равна:

$$D = 1 - \sum_{M=1}^{M_{\text{мис}}} \frac{P(M)}{C_M} \sum_{\Sigma l_i = M, l_i \in \{0,1\}} \prod_{i=1}^L P_i^{l_i} \left(1 - \exp \left(-T \left(\rho_i (1 + l_i g) \right) \right) \right)^N. \quad (7.3.6)$$

Вероятность ложной тревоги находится из (7.53) при $P(M) = d(M)$, $M = 0$, $g = 0$:

$$F = 1 - \prod_{i=1}^L \left(1 - \exp \left(-\frac{T}{\rho_i} \right) \right)^N. \quad (7.3.7)$$

Простой вид полученных аналитических выражений позволяет использовать их для расчета характеристик обнаружения при больших значениях L и $M_{\max}$, чем в предыдущих параграфах ($L < 50$, $M_{\max} < L/4$).

Одинаковые P_i . Весовые коэффициенты становятся одинаковыми, поэтому алгоритм (7.1.52) упрощается:

$$\Lambda_{31} = \max_{\substack{i=1,L \\ k=1,N}} \left\{ A_{ik}^2 \left(\frac{y}{\tau_{ik}} \right) \right\}, \quad (7.3.8)$$

Этот алгоритм обладает исключительной простотой. Время на его реализацию минимально: $T_{\Lambda_{31}} = L N t_{\leq}$, необходимая память также минимальна – $\Pi_{\Lambda_{31}} = 1$.

Характеристика обнаружения легко приводится к свернутому виду

$$D = 1 - \sum_{M=1}^{M_{\max}} P(M) (1-F)^{m_1/m} \left(1 - \left(1 - (1-F)^{1/m} \right)^{1/(1+g)} \right)^{m_2}, \quad (7.3.9)$$

где, как и ранее, $m = NL$; $m_1 = N(L - M)$; $m_2 = NM$.

Здесь можно не обращаться к методу статистического моделирования при больших значениях m , если имеется возможность представления чисел на ЭЦВМ с двойной точностью. Графики характеристик обнаружения алгоритма (7.3.8) представлены на рис. 7.22–7.24.




Рис. 7.22. Характеристики обнаружения алгоритма (7.3.8) при фиксированном первом параметре априорного распределения:
а – $F = 10^{-4}$; б – $F = 10^{-6}$

Сравнение графиков обоих алгоритмов приводит к выводу, что при малых и средних отношениях сигнал/шум алгоритм (7.3.8) проигрывает по качеству обнаружения алгоритму (7.1.16). Анализ зависимостей показывает, что чем больше отношение $\eta^2/(\eta + \nu)$, тем ближе характеристики обнаружения к прямой линии, которая на используемой системе координат означает характеристику обнаружения детерминированного сигнала в нормальных шумах, т. е. интеграл вероятности в зависимости от его аргумента.




Рис. 7.23. Характеристики обнаружения алгоритма (7.3.8) при фиксированном втором параметре:
а – $m = 8$; б – $m = 16$




Рис. 7.24. Характеристики обнаружения алгоритма (7.3.8)
при различных квазигaussianовых априорных распределениях:
а – $m = 8$; б – $m = 16$

На рис. 7.25 показаны зависимости вероятности правильного обнаружения от параметров априорного распределения. Отличительной особенностью при больших $\bar{G}$ является сильная зависимость от первого параметра. Как и ранее, имеется такое значение $\bar{G}$ (в данном случае ~ 15 дБ), при котором вероятность правильного обнаружения D алгоритма (7.3.8) не зависит от параметров априорного распределения.




Рис. 7.25. Влияние изменения второго (а) и первого (б) параметров априорного распределения на вероятности правильного обнаружения (7.3.8)




Рис. 7.26. Максимально достижимые вероятности правильного обнаружения алгоритма (7.3.8):
а – $F = 10^{-4}$; б – $F = 10^{-6}$

Графики на рис. 7.26 представляют зависимости максимально достижимых вероятностей правильного обнаружения $\bar{D}_{\max}$ при различных уровнях ложной тревоги. При малых и средних $\bar{G}$ величины $\bar{D}_{\max}$ практически совпадают, при больших – различаются, особенно для $\eta^2/(\eta + \nu) > 3$. Зависимости оптимального числа интервалов разрешения m_0 от отношения сигнал/шум $\bar{G}$ показаны на рис. 7.27.




Рис. 7.27. Оптимальное число объемов разрешения алгоритма (7.3.8):
а – $F = 10^{-4}$; б – $F = 10^{-6}$

Общий вывод из анализа графиков такой же, какой был сделан ранее для алгоритма (7.1.16): $m_0 = 1$ при малых $\bar{G}$ и $m_0 \leq 20$ при средних $\bar{G}$. Как и ожидалось, в среднем число m_0 у алгоритма (7.3.8) меньше, чем у алгоритма (7.1.16).

7.3.2. Квазиоптимальный алгоритм с межпериодным накоплением и выбором максимума

Как указывалось, рассмотренный в предыдущем пункте квазиоптимальный алгоритм с полным выбором максимума при формировании статистики не использует априорную информацию о характере движения ПРЦ. Если отказаться от выполненного выше крайнего упрощения оптимального алгоритма (6.1.15), то при тех же условиях (M мало, $g \rightarrow \infty$) для обнаружения дружно движущейся ПРЦ следует использовать

квазиоптимальный алгоритм с межпериодным накоплением и выбором максимума среди L накопленных отсчетов:

$$\Lambda_{32}(y) = \max_{i=1, L} \left\{ \rho_i \sum_{k=1}^N A_H^2 \left(\frac{y}{\tau_{ik}} \right) \right\}. \quad (7.3.10)$$

Время на вычисление статистики Λ_{32} больше, чем в предыдущем случае: $T_{\Lambda_{32}} = LNt_+ + L(t_x + t_{\leq})$, для хранения информации необходим больший объем памяти $\Pi_{\Lambda_{32}} = 2L + 1$ ячеек.

Неодинаковые P_i . Вероятность обнаружения рассчитывается по формуле

$$D = 1 - \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \sum_{\sum_{i=1}^L l_i = M} \prod_{i=1}^L P_i^{l_i} \left(1 - \frac{\Gamma(N, T/w_i)}{\Gamma(N)} \right), \quad (7.3.11)$$

где $\Gamma(N, T/w_i) = w_i^{-1} \int_T^{\infty} X^{N-1} e^{-X/w_i} dx$ – неполная гамма-функция,

$$w_i = \rho_i(1 + l_{gg}), \quad l_i \in \{0, 1\}.$$

Вероятность ложной тревоги находится согласно выражения

$$F = 1 - \prod_{i=1}^L \left(1 - \frac{\Gamma(N, T/\rho_i)}{\Gamma(N)} \right) \quad (7.3.12)$$

Использование этих аналитических выражений для определения характеристик обнаружения не встречает больших трудностей. Вычисление $\Gamma(N, X)$ следует проводить с помощью процедуры NG , описанной в [2].

Одинаковые P_i . При одинаковых вероятностях P_i алгоритм (7.3.10) имеет вид (он исследован в [16]):

$$\Lambda_{33}(y) = \max_{i=1, L} \left\{ \sum_{k=1}^N A_H^2 \left(\frac{y}{\tau_{ik}} \right) \right\}. \quad (7.3.13)$$

Машинное время и машинная память здесь меньше примерно в два раза, чем в предыдущем подпункте: $T_{\Lambda_{33}} = LNt_+ + Lt_-$, $\Pi_{\Lambda_{32}} = L + 1$. Вероятность правильного обнаружения определяется по формуле

$$D = 1 - \sum_{M=1}^{M_{\text{мисс}}} P(M) \left(1 - \frac{\Gamma(N, T/(1+gg))}{\Gamma(N)} \right)^M \left(1 - \frac{\Gamma(N, T)}{\Gamma(N)} \right)^{L-M}. \quad (7.3.14)$$

Вероятность ложной тревоги –

$$F = 1 - \left(1 - \frac{\Gamma(N, T)}{\Gamma(N)} \right)^L. \quad (7.3.15)$$

При заданной величине F необходимый порог легко может быть найден с помощью процедуры GIN , первый аргумент которой равен N , второй – $1 - (1 - F)^{1/L}$. Процедура $GIN(GIN)$ описана в [2]. Вычисление согласно выражению (7.61) проводится также относительно просто и быстро.

На рис. 7.28–7.30 представлены характеристики обнаружения алгоритма (7.3.13). На всех графиках видна одна и та же закономерность: при отношении сигнал/шум порядка 12–20 дБ вероятность правильного обнаружения при увеличении N уменьшается и довольно значительно, при больших G – возрастает. Чем больше отношение $\eta^2/(\eta + \nu)$, тем круче и прямолинейнее кривые, тем меньше выигрыш за счет увеличения N при одинаковой общей энергии отраженных сигналов.




Рис. 7.28. Характеристики обнаружения алгоритма (7.3.13) при равномерном (а) и малоэлементном (б) априорных распределениях

Например, на уровне $D = 0,995$ при $F = 10^{-4}$, $\frac{\eta^2}{\eta+v} = 0,5$ энергетический выигрыш $\Delta\bar{G} = 11,5$ дБ, при $\frac{\eta^2}{\eta+v} = 5$ он существенно меньше – $\Delta\bar{G} = 4,5$ дБ. Чем выше вероятность правильного обнаружения, тем больше значение $\Delta\bar{G}$. Увеличение N более 8 для $D < 0,9999$ практически нецелесообразно, поскольку даже при $\frac{\eta^2}{\eta+v} = 0,5$ в этом случае $\Delta\bar{G} < 2$ дБ.




Рис. 7.29. Характеристики обнаружения алгоритма (7.3.13) при квазигaussian априорных распределениях:
а – $\eta = v = 2$; б – $\eta = v = 5$




Рис. 7.30. Характеристики обнаружения алгоритма (7.3.13) при квазигaussian (а) и многоэлементном (б) априорных распределениях

На рис. 7.31 показаны зависимости вероятности правильного обнаружения от первого и второго параметров априорного распределения при $N = 8$. Анализ графиков показывает, что при любых отношениях сигнал/шум большому значению ν соответствует большая величина D . Характер влияния параметра η зависит от уровня $\bar{G}$: при большой величине возрастание η приводит к существенному увеличению D , при средних и, особенно, при малых $\bar{G}$ — к уменьшению D .




Рис. 7.31. Влияние изменения второго (а) и первого (б) параметров априорного распределения на вероятности правильного обнаружения алгоритма (7.3.13)

Влияние числа периодов повторения N на вероятность правильного обнаружения показано на рис. 7.32 и 7.33. Из графиков следует, что имеется оптимальное значение N_0 , при малых $\bar{G}$ равное единице, при котором вероятность правильного обнаружения наибольшая. С уменьшением числа интервалов разрешения или увеличением отношения сигнал/шум значение N_0 возрастает. При малых и средних $\bar{G}$ $N_0 = 1$ для $L \geq 4$; чем больше L , тем выше значение $\bar{G}$, при котором N_0 отличается от единицы. Априорное распределение также оказывает влияние на N_0 : чем меньше $\eta/(\eta + \nu)$, тем больше N_0 .

Зависимости максимальных вероятностей правильного обнаружения представлены на рис. 7.34. Это практически прямые линии, различие между ними за счет априорных распределений с увеличением

N уменьшается и при $N > 8$ его практически нет. Это объясняется тем, что $D_{\max}$ при $N \geq 8$ соответствует оптимальному числу элементов разрешения, равному единице, поэтому все априорные распределения вырождаются в $P(M) = d(M-1)$.




Рис. 7.32. Зависимости вероятностей правильного обнаружения алгоритма (7.3.13) от числа периодов повторения при равномерном распределении:
а – $L = 1$; б – $L = 8$




Рис. 7.33. Зависимости вероятностей правильного обнаружения алгоритма (7.3.13) от числа периодов повторения:
а – $L = 4$; б – $L = 8$




Рис. 7.34. Максимально достижимые вероятности правильного обнаружения алгоритма (7.3.13):
а – $N = 4$; б – $N = 8$

Графики на рис. 7.35 показывают, как зависит L_0 от величины $\bar{G}$. Хорошо видна тенденция уменьшения L_0 с увеличением N . При $N > 10$ в рассматриваемом диапазоне изменения $\bar{G}$ ($0 \leq \bar{G} \leq 30$ дБ) можно принять $L = 1$ для всех случаев априорного распределения.




Рис. 7.35. Оптимальное число объемов разрешения алгоритма (7.3.13) в зависимости от отношения сигнал/шум:
а – $N = 4$; б – $N = 8$

7.4. Квазиоптимальные алгоритмы с использованием порядковых статистик

В параграфе исследуются квазиоптимальные алгоритмы обнаружения ПРЦ, асимптотически оптимальные как при больших, так и при малых отношениях сигнал/шум и произвольном распределении числа элементов ПРЦ.

Предположим, что в формуле (6.1.15) $N = 1$ и значения реализаций $x_i = \ln B_i$ ранжированы и образуют вариационный ряд вида $x^{(1)} \geq x^{(2)} \geq \dots \geq x^{(L)}$. При увеличении отношения сигнал/шум g первыми членами во все возрастающем количестве актов будут становиться отсчёты, относящиеся к отраженным сигналам от обнаруживаемых элементов. При достаточно большой величине g среди первых M членов ряда практически будут отсутствовать шумовые отсчеты. На основании этого свойства вариационного ряда можно существенно упростить двойную сумму в (6.1.15). Поскольку среди всех $\binom{L}{M}$ сумм любых M членов ряда сумма его первых M членов наибольшая и с увеличением g все более отличается от остальных $\binom{L}{M} - 1$ сумм, то упрощенный алгоритм ($N = 1$) примет вид:

$$\Lambda_{40}(y) = \sum_{M=1}^{M_{\max}} \frac{P(M)}{C_M} \exp \left\{ \sum_{i=1}^M x^{(i)} \right\} = \sum_{M=1}^{M_{\max}} \exp \left(\beta_M + \sum_{i=1}^M x^{(i)} \right), \quad (7.4.1)$$

где $\beta_M = \ln \left(\frac{P(M)}{C_M} \right)$, $x^{(i)} = \ln B_{q_i}(y)$.

Практическая реализация этого алгоритма на неспециализированных ЭЦВМ невозможна вследствие выходящих за допустимые границы значений показателя экспоненты. Можно избавиться от этого недостатка, если формировать статистику согласно другому, более простому алгоритму

$$\Lambda_{41}(y) = \sum_{i=1}^{M_{\max}} \alpha_i x^{(i)}. \quad (7.4.2)$$

Однако в этом случае число разрядов арифметического устройства должно быть не менее 15–20. Коэффициент α_i сложным образом зависят от коэффициентов β_M в формуле (7.4.2). Отметим лишь, что они должны всегда образовывать невозрастающую с увеличением i последовательность, поскольку вес β_M каждой порядковой статистики уменьшается.

В качестве примера приведем нормированные средние значения порядковых статистик $x^{(i)}$ при обнаружении ПРЦ с релейским распределением амплитуд и при выбранных выше четырех типах априорных распределений числа элементов (рис. 7.36). Здесь число интервалов разрешения $L = 16$, число периодов $N = 1$, $M_{\max} = L$. Наибольшее влияние уровня отношения сигнал/шум на вид зависимостей $\hat{x}_n^{(i)} = f(i)$ наблюдается у малоэлементных ПРЦ, наименьшее – у многоэлементных ПРЦ. Абсолютные значения первых порядковых статистик $x^{(1)}$ практически пропорциональны отношению сигнал/шум.

Зависимость коэффициента наглядно представлена на рис. 7.37 при двух значениях L . По оси ординат отложено значение $\ln \alpha_i$, в обоих случаях $M_{\max} = L$. С точностью до ошибок моделирования можно утверждать:

1) при обнаружении многоэлементной ПРЦ коэффициенты α_i для любого отношения сигнал/шум должны быть одинаковыми, т. е. алгоритм с использованием порядковых статистик сводится к алгоритму аналогового накопления (см. 7.1);

2) в случае малоэлементной ПРЦ следует ограничиться только первой порядковой статистикой, поскольку коэффициент α_2 при второй статистике меньше в $\exp(14/L)$ раз и алгоритм порядковых статистик сводится к алгоритму с выбором максимума;

3) при обнаружении ПРЦ с квазигауссовым априорным распределением следует учитывать только первые $L/2$ порядковых статистик с уменьшением от α_1 до $\alpha_{L/2}$ примерно в $e = 2,82$ раз;

4) наконец, при обнаружении ПРЦ с равномерным распределением числа элементов необходимо использовать весь вариационный ряд, и коэффициенты α_i при этом должны изменяться по закону $\exp(-ai/L)$, где величина a зависит от отношения сигнал/шум, например, для $\bar{G} = 30$ дБ значение $a = 2,5$, а для $\bar{G} = 20$ дБ оно равно единице.




Рис. 7.36. Порядковые статистики при равномерном (а), многоэлементном (б), малоэлементном (в) и квазигaussianовом (г) априорных распределениях




Рис. 7.37 Зависимости коэффициента алгоритма (7.4.2) при равномерном (а), многоэлементном (б), малоэлементном (в) и квазигауссовом (г) априорных распределениях

Таким образом, алгоритм с использованием порядковых статистик в частных случаях может соответствовать рассмотренным выше алгоритмам с накоплением и выбором максимума, в общем случае он позволяет получить более высокую вероятность правильного обнаружения без изменения структуры алгоритма. Более того, если для некоторого значения отношения сигнал/шум, априорного распределения числа элементов ПРЦ и логарифма отношения правдоподобия $\ln B(y)$ рассчитать коэффициенты α_i , $i = 1, L$, как это сделано выше, то алгоритм с использованием порядковых статистик будет практически соответствовать оптимальному алгоритму обнаружения ПРЦ.

При этом по сравнению с оптимальным уменьшается объем вычислений, который здесь равен

$$T_{\Lambda_{41}} \simeq M_{\max} (t_x + t_+) + \frac{Lt_{\leq}}{2},$$

машинная память $\Pi_{\Lambda_{41}} = 2M_{\max} + 1$, но не преодолевается существенный недостаток, связанный с требованием априорного знания g , $P(M)$ и $\ln B(y)$.

7.4.1. Одинаковые P_i

Упростим оптимальный алгоритм обнаружения дружно движущейся ПРЦ (6.1.15) при больших отношениях сигнал/шум, отказавшись от операции экспонирования, как это было сделано ранее. Тогда квазиоптимальный алгоритм примет вид:

$$\Lambda_{42}(y) = \sum_{i=1}^{M_{\max}} \alpha_i \left(\sum_{k=1}^T p_j x_{jk} \right)^{(i)}, \quad (7.4.3)$$

где операция $(\cdot)^{(i)}$ означает нахождение i -й порядковой статистики. Максимальное время на формирование Λ_{42} равно

$$T_{\Lambda_{42}} \simeq M_{\max} (t_x + 1/2t_{\leq}) + LNt_+,$$

машинная память составляет $\Pi_{\Lambda_{42}} = M_{\max} + 2L + 1$ ячеек.

Определим вероятность ложной тревоги алгоритма (7.4.3) в наиболее простом случае: $\rho_i = 1$, $i = \overline{1, L}$; $N = 1$. Совместная плотность вероятности всех L порядковых статистик имеет вид [17]:

$$f_L(U_1, \dots, U_L) = L! \left[(S_L - 1)! (S_L - S_{L-1} - 1)! \dots (L - S_1)! \right]^{-1} F_1^{S_L-1}(U_L) \times \\ \times \left[F_1(U_{L-1}) - F(U_L) \right]^{S_L - S_{L-1} - 1} \dots \left[1 - F_1(U_1) \right]^{L - S_1} \prod_{i=1}^L f_1(U_i), \quad (7.4.4)$$

где $F_1(\cdot)$ – функция распределения случайных величин, из которых образуется вариационный ряд или генеральная функция распределения;

$f_1(\cdot)$ – генеральная плотность вероятности;

S_L – номер порядковой статистики.

В данном случае S_L образует натуральный ряд от 1 до L , поэтому

$$f_L(U_1, \dots, U_L) = L! \prod_{i=1}^L f_1(U_i). \quad (7.4.5)$$

Многомерная характеристическая функция, соответствующая совместной плотности вероятности (7.4.5), определяется прямым L -мерным преобразованием Фурье:

$$\varphi_L(t_1, \dots, t_L) = L! \int_{-\infty}^{+\infty} dx_1 \int_{-\infty}^{x_1} dx_2 \dots \int_{-\infty}^{x_{L-1}} dx_L f_L(x_1, \dots, x_L) e^{-jx_1 t_1} \dots e^{-jx_L t_L} = \\ = L! \int_0^\infty f_1(x_1) e^{-jx_1 t_1} \int_0^{x_1} f_1(x_2) e^{-jx_2 t_2} \dots \int_0^{x_{L-1}} f_1(x_L) e^{-jx_L t_L} dx_L \dots dx_1. \quad (7.4.6)$$

Здесь нижние пределы у интегралов равны нулю, поскольку случайные величины $x_i \geq 0$. При релеевском распределении амплитуд отраженных сигналов генеральное распределение $F_1(\cdot)$ является экспоненциальным, характеристическая функция которого $\varphi_1(t) = 1/(1 + jt)$.

Проведем вычисление $\varphi_L(t_1, \dots, t_L)$ последовательно, начиная со значения $L = 1$, при котором $\varphi_1(t_1) = \varphi_1(t) = (1 + jt)^{-1}$. При $L = 2$

$$\varphi_2(t_1, t_2) = 2! \int_0^\infty e^{-x_1(1+jt_1)} \int_0^{x_1} e^{-x_2(1+jt_2)} dx_2 dx_1 = \frac{2!}{(1+jt)(2+jt_1+jt_2)},$$

при $L = 3$

$$\begin{aligned} \varphi_3(t_1, t_2, t_3) &= 3! \int_0^\infty e^{-x_1(1+jt_1)} \int_0^{x_1} e^{-x_2(1+jt_2)} \int_0^{x_2} e^{-x_3(1+jt_3)} dx_3 dx_2 dx_1 = \\ &= \frac{3!}{(1+jt)(2+jt_1+jt_2)(3+jt_1+jt_2+jt_3)}. \end{aligned}$$

Методом математической индукции можно показать, что в общем случае

$$\varphi_2(t_1, \dots, t_L) = \frac{L!}{\prod_{k=1}^L \left(k + j \sum_{i=1}^k t_i \right)}. \quad (7.4.7)$$

Поставив вместо t_i в (7.4.5) $\alpha_i t$, получим характеристическую функцию взвешенных сумм L порядковых статистик при отсутствии отраженных сигналов:

$$\varphi_{\text{ш}}(t) = \frac{L!}{\prod_{k=1}^L \left(k + jt \sum_{i=1}^k \alpha_i \right)} = \frac{1}{\prod_{i=1}^k (1 + jb'_i t)}, \quad (7.4.8)$$

$$\text{где } b'_k = \frac{1}{k} \sum_{i=1}^k \alpha_i.$$

Вероятность ложной тревоги определяется интегралом в пределах от T до ∞ от обратного преобразования Фурье от функции (7.4.8):

$$F = \sum_{r=1}^L \frac{e^{-T/b'_r}}{\prod_{\substack{k=1 \\ k \neq r}}^L (1 - b'_k/b'_r)}. \quad (7.4.9)$$

Процедура FIN , с помощью которой для заданной F находится порог T , приведена в [2].

Определим вероятность правильного обнаружения алгоритма (7.4.3) при названных выше условиях и разрешенных сигналах от отдельных элементов ПРЦ. Обозначим парциальной многомерной характеристической функцией характеристическую функцию ситуации, когда имеется M сигнальных и $L - M$ шумовых отсчетов в вариационном ряду. Положение членов вариационного ряда, создаваемых сигнальными отсчетами, среди шумовых жестко фиксировано. Перестановки только среди шумовых или

среди сигнальных отсчетов не меняют вида парциальной характеристической функции. Таких перестановок имеется $M!(L-M)!$. Перестановки же среди разнородных членов вариационного ряда при одинаковом их числе изменяют вид парциальной характеристической функции. Число разнородных перестановок равно $\binom{L}{L-M}$. Общая характеристическая функция равна сумме парциальных функций:

$$\begin{aligned}\varphi_M(t_1, \dots, t_L) &= M!(L-M)! \sum \binom{L}{M} \varphi_M^{\text{пар}}(t_1, \dots, t_L) = \\ &= M!(L-M)! \sum_{s=1}^{\binom{L}{M}} \frac{(1+g)^{-M}}{(\alpha_1^{(s)} + jt_1)(\alpha_2^{(s)} + jt_1 + jt_2) \dots (\alpha_L^{(s)} + jt_1 + jt_L)}.\end{aligned}\quad (7.4.10)$$

Здесь $\alpha_i^{(s)} = \sum_{k=1}^i C_k$, где $C_k = 1$, если на k -м месте в вариационном ряду стоит шумовой отсчет, и $C_k = (1+g)^{-1}$, если на этом месте стоит сигнальный отсчет. Верхний индекс s означает одно из возможных сочетаний. Методика получения (7.4.10) аналогична использованной выше. Характеристическая функция распределения статистики Λ_{42} при наличии отраженных сигналов записывается на основании выражения (7.72):

$$\varphi_{c+\text{ш}}(t) = \sum_{M=1}^{M_{\text{макс}}} P(M) M!(L-M)! (1+gg)^{-M} \sum_{q=1}^{\binom{L}{M}} \frac{1}{\prod_{k=1}^L (\alpha_k^{(q)} + jb_k t)}, \quad (7.4.11)$$

где $b_k = \sum_{i=1}^k \alpha_i$, $k = \overline{1, L}$.

Вероятность правильного обнаружения находится обратным преобразованием Фурье от $\varphi_{c+\text{ш}}(t)$ и интегрированием в пределах от T до ∞ :

$$D = \sum_{M=1}^{M_{\text{макс}}} \frac{P(M) M!(L-M)!}{(1+gg)^M} \sum_{q=1}^{\binom{L}{M}} \sum_{k=1}^L \frac{e^{-\alpha_k^{(q)} T / b_k}}{\alpha_k^{(q)} \prod_{\substack{l=1 \\ l \neq k}}^L (\alpha_l^{(q)} - \alpha_k^{(q)} b_l / b_k)}. \quad (7.4.12)$$

Практические расчеты характеристик обнаружения с использованием (7.4.12) связаны с большими трудностями. Произведение, стоящее в знаменателе, велико по абсолютной величине и знакопеременно, поэтому уже при L и $M_{\text{макс}} > 8$ ошибки округления настолько велики, что единственным методом отыскания характеристик обнаружения является метод статистического моделирования.

Найдем вероятность ложной тревоги алгоритма (7.4.3) при $\rho_i = 1$ и произвольном N для релеевой модели отраженных сигналов. В этом случае генеральным распределением является γ -распределение

$$f(x) = x^{N-1} e^{-x} / \Gamma(N).$$

Воспользуемся возможностью дифференцирования выражения (68) по параметру. Многомерная производная от характеристической функции $\Phi_L(t_1, \dots, t_L)$ равна:

$$\begin{aligned} & \frac{(j)^{L(N-1)}}{[\Gamma(N)]^L} \frac{\partial^{N-1}}{\partial t_1^{N-1}} \dots \frac{\partial^{N-1}}{\partial t_L^{N-1}} \Phi_L(t_1, \dots, t_L) = \\ & = \frac{L!}{[\Gamma(N)]^L} \int_0^\infty f_1(x_1) x_1^{N-1} e^{-jx_1 t_1} \dots \int_0^{x_{L-1}} f_1(x_L) x_L^{N-1} e^{-jx_L t_L} dx_L \dots dx_1. \end{aligned} \quad (7.4.13)$$

Если принять $f_1(x_i) = e^{-x_i}$, то (7.4.13) совпадает с характеристической функцией $\Phi_L(t_1, \dots, t_L)$ распределения Λ_{42} при произвольном значении N . Обозначим

$$\begin{aligned} \Phi_i &= \frac{1}{i + jt_1 + jt_2 + \dots + jt_i}; \\ \Phi_i(r_{i-m}, r_{i-m+1}, \dots, r_i) &= \frac{\partial^{r_{i-m}}}{\partial t_{i-m}^{r_{i-m}}} \frac{\partial^{r_{i-m+1}}}{\partial t_{i-m+1}^{r_{i-m+1}}} \dots \frac{\partial^{r_i}}{\partial t_i^{r_i}} \Phi_i = (-j)^R R! \Phi_i^{R+1}, \end{aligned}$$

$$\text{где } R = \sum_{k=i-m}^i r_k ..$$

Тогда многомерная характеристическая функция имеет вид:

$$\Phi_L(t_1, \dots, t_L) = \frac{j^{L(N-1)}}{[\Gamma(N)]^L} \sum_{(N)} \prod_{i=1}^L \binom{N-1}{\vec{n}_i} \Phi_i(\vec{n}_i), \quad (7.4.14)$$

где векторы $\vec{n}_i$ и $\vec{n}_k$ являются соответствующими строками и столбцами целочисленной матрицы

$$\mathbb{N} = \begin{bmatrix} n_{11} & n_{12} & n_{13} & \dots & n_{1,L-1} & n_{1L} \\ 0 & n_{22} & n_{23} & \dots & n_{2,L-1} & n_{2L} \\ 0 & 0 & n_{33} & \dots & n_{3,L-1} & n_{3L} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 0 & n_{LL} \end{bmatrix},$$

в которой сумма элементов каждой строки равна $N - 1$; $n_{ik} = 0$, $k < i$. В (7.1.76) сумма берется по всем возможным наборам $\{N\}$ чисел, записанным в матрице $\mathbb{N}$. Таким образом, вероятность ложной тревоги равна

$$F = L! \sum_{\{N\}} \prod_{i=1}^L \frac{1}{\prod_{k=i}^L n_{ik}} R!(i)^{-(R+i)} I_k(\vec{w}, \vec{m}, T), \quad (7.4.15)$$

где $k = L$; $w_i = b'_i = \frac{1}{i} \sum_{k=1}^i \alpha_k$; $m_i = R + 1 = \sum_{k=1}^i n_{ki} + 1$.

7.4.2. Неодинаковые P_i

Определим также вероятность ложной тревоги при $N = 1$ и различных P_i . Многомерная характеристическая функция $\Phi_L(t_1, \dots, t_L)$ находится тем же методом, что и в начале пункта:

$$\Phi_L(t_1, t_2, \dots, t_L) = \frac{L!}{\prod_{i=1}^L \rho_i} \left\{ \frac{1}{\prod_{i=1}^L \left(\sum_{k=1}^i 1/\rho_k + j \sum_{k=1}^i t_k \right)} \right\}_{\text{sim}(L)}, \quad (7.4.16)$$

где символ $\{\cdot\}_{\text{sim}(L)}$ обозначает операцию симметрирования [18] стоящей в фигурных скобках функции относительно аргументов ρ_k и t_k . Число

аргументов указано после знака *sim*. Тогда величина F для этого случая определяется согласно выражения:

$$F = \frac{L!}{\prod_{i=1}^L \rho_i} \left\{ \sum_{r=1}^L \frac{e^{-T/b_r}}{\alpha_r \prod_{\substack{k=1 \\ k \neq r}}^L (1 - b_k/b_r) \alpha_k} \right\}_{sim(L)}, \quad (7.4.17)$$

где $\alpha_r = \sum_{i=1}^r 1/\rho_i$, $b_r = \sum_{i=1}^r \alpha_i / a_r$, а симметрирование проводится дружно по всем L значениям α_i и ρ_i .

Определение вероятности ложной тревоги по выражениям (7.4.15) и (7.4.15) можно проводить при малых L . При $N > 8$ следует использовать гауссовскую аппроксимацию для суммы $\sum_{k=1}^N x_{ik}$, предполагая тем самым, что генеральное распределение является нормальным $N(N, N)$.

Отыскание точных аналитических выражений для F в общем случае и D для условий, использованных при вводе (7.4.15) и (7.4.17), следует признать нецелесообразным, поскольку большая сложность формул делает невозможным расчет F и D при $L > 4$.

Методом статистического моделирования ($Q = 1000$) были получены численные характеристики обнаружения алгоритма (7.4.3) при $\rho_i = 1$, $i = \overline{1, L}$, и весовых коэффициентах $\alpha_i = c^i$, образующих геометрическую прогрессию [2]. Графики характеристик, изображенные на рис. 7.38 и 7.39 и помеченные цифрами 6, 7, 8, 9 соответствуют показателям прогрессии $c = 0,1; 0,2; 0,5; 0,8$. Проведен также анализ случая $c = 0,9$. Для сравнения на этих рисунках построены характеристики обнаружения алгоритмов с накоплением (обозначена цифрой 1) и выбором максимума (обозначена цифрой 5). Графики построены для случаев, когда различие между характеристиками может быть представлено графически.

Из всех приведенных ситуаций обнаружения лишь при равномерном распределении числа элементов алгоритм (7.4.3) обнаруживает ПРЦ лучше других (при $\bar{G} = 20$ дБ), но различие между ними и алгоритмом с накоплением (1) невелико и равно примерно 0,2 дБ (см рис. 7.39, а, кривая 9). Во всех остальных ситуациях алгоритмы по качеству обнаружения расставляются в такой последовательности: 1, 10, 9, 8, 7, 6 и 5.




Рис. 7.38. Характеристики обнаружения алгоритмов (7.1.16), (7.3.8) и (7.4.3) при равномерном (а) и малоэлементном (б) априорных распределениях




Рис. 7.39. Характеристики обнаружения алгоритмов (7.1.16), (7.3.8) и (7.4.3) при многоэлементном априорном распределении:
а – $m = 8$; б – $m = 16$

В диапазоне изменений показателя геометрической прогрессии от 0,4 до 0,6 (кривая 8) наблюдается более резкая зависимость D от c . Следует отметить, что использование других законов изменения коэффициентов α_i , например, таких, какие приведены в начале параграфа, приводит к незначительному относительному сдвигу характеристик обнаружения алгоритма (7.4.3), соответствующему второму порядку малости взаимных проигрышей и выигрышей в пороговом сигнале.

Итак, использование алгоритма с порядковой статистикой в рассмотренных ситуациях обнаружения не дает практически никаких выигрышей в пороговом сигнале и от него вполне можно отказаться. Этот вывод тем более справедлив еще и потому, что реализация алгоритмов с использованием порядковых статистик наталкивается на большие вычислительные трудности.

7.5. Квазиоптимальные комбинированные алгоритмы

Исследования квазиоптимальных алгоритмов с аналоговым накоплением и выбором максимума показало, что эти алгоритмы близки к оптимальному при альтернативных условиях, причем взаимная замена их невозможна вследствие резкого ухудшения характеристик обнаружения. Выбор того или другого алгоритма производится на основе априорных сведений об отношении сигнал/шум и распределении числа элементов ПРЦ или хотя бы его первого момента. Если этих сведений нет, то вследствие неправильного выбора возможны существенные потери в пороговом сигнале. С целью уменьшения этих потерь предлагается использовать для обнаружения ПРЦ комбинированные алгоритмы, являющиеся логической комбинацией алгоритмов с накоплением и выбором максимума, и, тем самым, априорным способом уменьшить влияние априорной неопределенности на характеристики обнаружения.

7.5.1. Комбинированный алгоритм с аналоговым накоплением и полным выбором максимума

Этот квазиоптимальный алгоритм представляет собой логическое объединение алгоритмов Λ_{10} и Λ_{30} :

$$\Lambda_{50}(y) = 1[\Lambda_{10}(y) - T_1] + 1[\Lambda_{30}(y) - T_2], \quad (7.5.1)$$

где T_1 и T_2 – пороги первый и второй, $\Lambda_{10}(y)$ и $\Lambda_{30}(y)$ – первая и вторая статистики. Целочисленная статистика Λ_{50} может принимать три значения: 0, 1 и 2, и, если она отлична от нуля, то ПРЦ считается обнаруженной. Время на реализацию этого алгоритма на ЭЦВМ равно $T_{\Lambda_{50}} = T_{\Lambda_{10}} + LNt_{\leq\leq}$, машинная память занимает $\Pi_{\Lambda_{50}} = \Pi_{\Lambda_{10}} + 2$ ячеек.

Найдем характеристики обнаружения при одинаковых $P_i, i = \overline{1, L}$ и релеевской модели отраженных сигналов, обозначив $n = NL$. Вероятность ложной тревоги соответствует вероятности $F = 1 - P_r (\Lambda_{10} < T_1, \Lambda_{30} < T_2)$. Характеристическая функция ограниченной экспоненциально распределенной случайной величины $x_i < T_2$ имеет вид:

$$\varphi_1(t) = \left(\frac{1 - e^{-T_2(1+jt)}}{(1+jt)(1 - e^{-T_2})} \right). \quad (7.5.2)$$

Величина $\bar{F} = 1 - F = P_r (\Lambda_{10} < T_1, \Lambda_{30} < T_2)$ может быть найдена интегрированием обратного преобразования Фурье от n -ой степени характеристической функции (7.5.2):

$$\bar{F} = \frac{(1 - e^{-T_2})}{2\pi} \int_0^T \int_{-\infty}^{+\infty} \varphi_1^n(t) e^{jtx} dt dx = \sum_{i=0}^{\left\lfloor \frac{T_1}{T_2} \right\rfloor} (-1)^{i+1} \binom{L}{i} \left[e^{-T_1} \sum_{a=0}^{n-1} \frac{(T_1 - iT_2)^a}{a!} - e^{-iT_2} \right].$$

Итак, вероятность ложной тревоги равна:

$$F = 1 + \sum_{i=0}^{\left\lfloor \frac{T_1}{T_2} \right\rfloor} (-1)^i \binom{L}{i} \left[e^{-T_1} \sum_{a=0}^{n-1} \frac{(T_1 - aT_2)^a}{a!} - e^{-iT_2} \right], \quad (7.5.3)$$

где операция $[x]$ означает взятие целой части от x .

Если порог T_1 стремится к бесконечности (в частности $T_1 > nT_2$), то комбинированный алгоритм вырождается в алгоритм выбора максимума, если T_2 стремится к бесконечности (в частности $T_2 > T_1$), то он соответствует алгоритму с аналоговым накоплением. Таким образом, выбором порогов T_1 и T_2 можно регулировать коэффициент участия статистик Λ_{10} и Λ_{30} в общей статистики обнаружения Λ_{50} , изменяя его от нуля до единицы. В [2] приводится процедура *SUMXIN*, с помощью которой для заданных значений вероятности ложной тревоги и коэффициента участия можно вычислить оба порога. Вероятность правильного

обнаружения находится методом, аналогичным использованному выше, и определяется формулой

$$\begin{aligned}
 D = 1 + \sum_{M=1}^{M_{\max}} P(M) \sum_{a=0}^{\left\lfloor \frac{T_1}{T_2} \right\rfloor} \sum_{b=0}^{\left\lfloor \frac{T_1-a}{T_2} \right\rfloor} (-1)^{a+b} \binom{m_1}{a} \binom{m_0}{b} \left[\frac{(-1)^{m_1} e^{-T_1+T_2 a g G} G^{m_1}}{(m_1-1)!} \times \right. \\
 \times \sum_{c=0}^{m_0-1} \sum_{d=0}^{m_0-c-1} \frac{(n-c-d-2)!}{c!(m_0-c-d-1)!} (T_1-T_2(a+b))^c (1-G)^{-n+c+d+1} + \quad (7.5.4) \\
 \left. + \frac{(-1)^{m_1} e^{-GT_1-GgbT_2}}{(m_1-1)!} \sum_{c=0}^{m_1-1} \sum_{d=0}^{m_1-c-1} \frac{(n-c-d-2)!}{c!(m_1-c-d-1)!} (T_1-T_2(a+b))^c \times \right. \\
 \left. \times G^{-1-d} (1-G)^{-n+c+d+1} - e^{-T_2(aG+b)} \right].
 \end{aligned}$$

где $m_1 = NM$; $m_0 = N(L-M)$; $n = NL$; $G = 1/(1+g)$.

На рис. 7.40 изображены характеристики обнаружения алгоритма (7.5.1), вычисленные методом статистического моделирования при одинаковых P_i . Число испытаний равно 1000. Пороги T_1 и T_2 в (7.5.1) выбраны такими, чтобы обеспечивались следующие соотношения между отдельными ветвями комбинированного алгоритма:

- 1) комбинированный полностью сводится к алгоритму с накоплением;
- 2) доля алгоритма с накоплением в комбинированном равна 0,7;
- 3) доля алгоритма с накоплением в комбинированном равна 0,5;
- 4) доля алгоритма с накоплением в комбинированном равна 0,3;
- 5) комбинированный полностью сводится к алгоритму с выбором максимума.

Как следует из анализа графиков, приведенных на крайних ситуациях – много- и малоэлементной ПРЦ – характеристики обнаружения комбинированного алгоритма занимают промежуточные положения по отношению к характеристикам обнаружения алгоритмов с накоплением и выбором максимума. В целом, они лежат ближе к характеристикам того алгоритма, который является наилучшим из них для данной ситуации обнаружения. При этом максимальные потери комбинированного алгоритма по сравнению с наилучшим не превышают 0,5–0,8 дБ, в то время как выигрыш по сравнению с наихудшим может достигать 3,5–4,5 дБ. В наибольшей степени это свойство комбинированного алгоритма проявляется при средних отношениях сигнал/шум, когда не выполняются условия

асимптотической близости к оптимальному алгоритму с накоплением и выбором максимума. В некоторых случаях (равномерное распределение числа элементов ПРЦ, $15 \text{ дБ} \leq \bar{G} \leq 25 \text{ дБ}$) комбинированный алгоритм обнаруживает ПРЦ с большей вероятностью, чем тот или иной из его составляющих (выигрыш до 0,5 дБ). Эти результаты говорят о том, что комбинированный алгоритм (7.5.1) может в значительной мере снизить, а иногда и устранить отрицательное влияние априорной неопределенности о числе элементов ПРЦ и отношении сигнал/шум на характеристики обнаружения. При этом наилучшее соотношение между составляющими комбинированного алгоритма лежит в области одинакового долевого участия в общем результате обнаружения, т. е. соотношение, примерно соответствующее названному выше случаю 3.





Рис. 7.40. Характеристики обнаружения алгоритма (7.5.1).

Параметр — степень участия алгоритма с накоплением в общей статистике обнаружения

На рис. 7.41 представлены характеристики обнаружения в зависимости от параметра L — числа интервалов разрешения. Крутизна характеристик с увеличением L в целом растет. Граничное значение отношения сигнал/шум, выше которого возрастание L приводит к увеличению вероятности правильного обнаружения, а ниже — к её уменьшению, находится в диапазоне от 16 до 18 дБ.






Рис. 7.42. Характеристики обнаружения алгоритма (7.5.1).
Параметр – тип априорного распределения

Представленные на рис. 7.43 зависимости вероятностей правильного обнаружения при различных порогах T (вероятностях ложной тревоги F) показывают, что с возрастанием T (уменьшении F) характеристики обнаружения практически параллельно переносятся в область больших значений отношений сигнал/шум.




Рис. 7.43. Характеристики обнаружения алгоритма (7.5.1).
Параметр – вероятность ложной тревоги

7.5.2. Комбинированные алгоритмы с аналоговым накоплением и межпериодным выбором максимума

При обнаружении дружно движущейся ПРЦ необходимо использовать в канале выбора максимума статистики, соответствующие сумме отсчетов за время наблюдения в L интервалах разрешения:

$$\Lambda_{32}(y) = 1[\Lambda_{10}(y) - T_1] + 1[\Lambda_{32}(y) - T_2]. \quad (7.5.5)$$

Решение о наличии ПРЦ принимается, если Λ_{31} отлично от нуля. Время на его реализацию на ЭЦВМ равно $T_{\Lambda_{31}} = T_{\Lambda_{10}} + Nt_{\leq} + 3t_+$, необходимая машинная память составляет $\Pi_{\Lambda_{31}} = 2L + 3$ ячеек.

Из характеристик обнаружения удалось найти выражение для вероятности ложной тревоги при одинаковых значениях P_f . Характеристическая функция ограниченной случайной величины, имеющей гамма-распределение, равна

$$\varphi_1(t) = \frac{1 - e^{-T_2(1+jt)} \sum_{a=0}^{N-1} \frac{[T_2(1+jt)]^a}{a!}}{\left(1 - e^{-T_2} \sum_{a=0}^{N-1} \frac{T_2^a}{a!}\right) (1+jt)^N}. \quad (7.5.6)$$

Величина F определяется соотношением

$$\begin{aligned} F &= 1 - \left(1 - e^{-T_2} \sum_{a=0}^{N-1} \frac{T_2^a}{a!}\right)^L \int_0^{T_1} \int_{-\infty}^{+\infty} \frac{\varphi_1(t) e^{jtx}}{2\pi} dt dx = \\ &= 1 + \sum_{i=0}^{\left[\frac{T_1}{T_2}\right]} (-1)^i \binom{L}{i} \left[e^{-T_1} \sum_{a=0}^{LN-1} \frac{(T_1 - aT_2)^a}{a!} - e^{-iT_2} \left(\sum_{a=0}^{N-1} \frac{T_2^a}{a!} \right)^i \right]. \end{aligned} \quad (7.5.7)$$

Как и в предыдущем алгоритме, выбором порогов T_1 и T_2 можно регулировать коэффициент участия статистик Λ_{10} и Λ_{32} в принятии решения об обнаружении ПРЦ. Процедура *SUMSIN*, с помощью которой для заданных значений F и F_{10} или F_{32} можно вычислить оба порога, приведена в [2].

При $N > 2$ в качестве первого приближения для вероятности правильного обнаружения следует использовать оценку снизу:

$$D_{\Lambda_{52}} \geq \max(D_{\Lambda_{10}}, D_{\Lambda_{32}}), \quad (7.2)$$

где вероятности правильного обнаружения $D_{\Lambda_{10}}$ и $D_{\Lambda_{32}}$ вычисляются соответственно по формулам (7.13) и (7.58) при подстановке в них порогов T_1 и T_2 .

На рис. 7.44 приведены характеристики обнаружения комбинированного алгоритма (7.84), полученные методом статистического моделирования. Число испытаний равно 1000, полная энергия отраженных сигналов одинакова во всех ситуациях ($\rho_i = 1$, $i = \overline{1, L}$). С увеличением числа периодов повторения крутизна характеристик возрастает, причем поворот кривых наблюдается в области значений отношений сигнал/шум $\overline{G}_a = (12...14)$ дБ при малоэлементных ПРЦ и $\overline{G}_a = (17...18)$ дБ при квазигауссовом распределении числа её элементов. С ростом N вероятность правильного обнаружения для $\overline{G} > \overline{G}_a$ увеличивается. Например, выигрыш в отношении сигнал/шум на уровне $D = 0,95$ при $N = 4$ составляет 5 дБ по сравнению с $N = 1$ (рис. 7.44, а). Если $\overline{G} > \overline{G}_a$, то влияние числа периодов накопления N на характеристики противоположно.

Интересный случай показан на рис. 7.45, где произведение числа интервалов разрешения на число периодов повторения равно постоянной величине – $NL = 16$. Общим является то, что при постоянном $m = NL$ с увеличением N или L растет крутизна характеристик обнаружения. Различие состоит в том, что на этот рост существенное влияние оказывает распределение числа элементов ПРЦ: он наиболее заметен у малоэлементных и с равномерным распределением, наименее – у многоэлементных и с квазигауссовым распределением. В первом случае выигрыш в отношении сигнал/шум может достигать 5 дБ. Вместе с тем увеличение N , т.е. расщепление суммарной энергии зондирующего сигнала на большее число периодов повторения, приводит к увеличению времени обнаружения, а при малых отношениях сигнал/шум – к снижению качества обнаружения ПРЦ.




Рис. 7.44. Характеристики обнаружения алгоритма (7.5.5) при малоэлементном (а) и квазигaussianовом (б) распределениях




Рис. 7.45. Влияние соотношения между числом объемов разрешения и числом периодов повторения на характеристики обнаружения: а – малоэлементное; б – квазигaussianовое априорные распределения

Таким образом, при использовании комбинированного алгоритма (7.5.5) следует ограничить число периодов повторений десять – шестнадцать при соответствующем уменьшении числа объемов разрешения до четырех – двух. На предельных дальностях обнаружения РЛС энергию зондирующего сигнала необходимо сосредотачивать в одиночный импульс с объемом разрешения, приближенно совпадающим с объемом, занимаемом ПРЦ.

7.6. Литература к главе 7

1. Хелстром К. Статистическая теория обнаружения сигналов / К. Хелстром: пер. с англ. Под ред. Ю.Б. Кобзарева. М.: Изд-во иностр. лит-ры, 1963. 431 с.
2. Исследование алгоритмов обнаружения групповой цели / Л.Г. Доросинский, В.Г. Коберниченко, М.П. Трухин / В кн. Обработка сигналов от распределённых целей в гауссовых и негауссовых помехах. Свердловск: УПИ им. С.М. Кирова, 1977.
3. Крылов В.И. Вычислительные методы / В.И. Крылов, В.В. Бобков, П.И. Монастырный. Т. 1. М.: Наука, 1976. 304 с.
4. Обнаружение пространственно-распределённых целей / Г. Ван дер Спек. Зарубежная радиоэлектроника, №9, 1972. С. 3-16.
5. Лебедев Н.Н. Специальные функции и их приложения / Н.Н. Лебедев. М.: Гостехиздат, 1953. 379 с.
6. Лезин Ю.С. Оптимальные фильтры и накопители импульсных сигналов / Ю.С. Лезин. М.: Советское радио, 1966. 448 с.
7. Прохоров Ю.В. Теория вероятностей: Основные положения. Пределные теоремы. Случайные процессы / Ю.В. Прохоров, Ю.А. Розанов. М.: Наука, 1973. 496 с.
8. Рекуррентный метод вычисления коэффициентов ряда Грама-Шарлье / Е. Бильери. ТИИЭР. Т. 61, №2. 1973.
9. Лихарев В.А. Цифровые методы и устройства в радиолокации / В.А. Лихарев. М.: Советское радио, 1973. 456 с.
10. Анализ двухэтапного обнаружителя случайного потока сигналов / Л.Г. Доросинский, М.П. Трухин. Радиотехника и электроника. Т. 23, №10. 1978. С. 2132-2136.
11. Егорычев Г.П. Интегральное представление и вычисление комбинаторных сумм / Г.П. Егорычев. Новосибирск: Наука, 1977. 285 с.
12. Фано Р. Передача информации: Статистическая теория связи / Р. Фано: пер. с англ. Под ред. Р.Л. Добрушина. М.: Мир, 1965. 439 с.
13. Ван Трис Г. Теория обнаружения, оценок и модуляции / Г. Ван Трис : пер. с англ. М.: Советское радио, 1972-1977. Т. 1. Теория обнаружения, оценок и линейной модуляции / под ред. В.И. Тихонова. 1972. 744 с. Т. 3. Обработка сигналов в радио- и гидролокации и приём случайных гауссовых сигналов на фоне помех / под ред. В.Т. Горяинова. 1977. 663 с.

14. Исследование обнаружения повторяющихся сигналов в шуме при помощи накопления / Д.В. Харрингтон: Приём сигналов при наличии шума / пер с англ. Под ред. Л.С. Гуткина. М.: Иностранная литература, 1960. 242 с.
15. Кендалл М. Теория распределений / М. Кендалл, А. Стьюарт. М.: Наука, 1966. 706 с.
16. Алгоритм обнаружения потока разрешённых сигналов / Л.Г. Доросинский, М.П. Трухин / В кн.: Пробл. повышения эффективности и качества радиотехн. систем. Вып. 1. Свердловск: изд-е УПИ, 1978. С. 47-51.
17. Левин Б.Р. Теоретические основы статистической радиотехники / Б.Р. Левин. Т. 3. М.: Советское радио, 1976. 288 с.
18. Большаков И.А. Статистические проблемы выделения потока сигналов из шума / И.А. Большаков. М.: Советское радио, 1969. 464 с.
19. Исследование квазиоптимальных алгоритмов обнаружения пространственно-распределённых целей с учетом их технической реализации / М.П. Трухин / В кн. Проблемы качества радиотехн. Вып. 3. Свердловск: изд-е УПИ, 1980.
20. Синтез и исследование алгоритмов обнаружения сигналов, отражённых от случайного числа пространственно-распределённых объектов / Л.Г. Доросинский, М.П. Трухин / В кн. Проблемы радиолокации протяженных объектов. Свердловск: изд-е УПИ,

8. ИССЛЕДОВАНИЕ АЛГОРИТМОВ ОЦЕНИВАНИЯ ОБЩЕГРУППОВЫХ ПАРАМЕТРОВ ПРЦ

Наряду с задачей обнаружения в многофункциональных РЛС (МРЛС) решаются задачи, связанные с оцениванием параметров, сопровождением и распознаванием ПРЦ. Для повышения точности оценивания применяют зондирующие сигналы с высокой разрешающей способностью. Поэтому существенно возрастает общее число объемов разрешения в секторе ответственности РЛС, взаимосвязь между отраженными сигналами, как пространственная, так и параметрическая, становится также очень сложной. Обработка больших объемов радиолокационной информации даже с использованием сверхбыстродействующих стационарных ЭЦВМ, входящих в состав МРЛС, представляет трудную проблему, решению которой посвящены многочисленные работы [1, 2, 3, 4, 5, 6]. Интерес специалистов к этой проблеме не ослабевает, поскольку высоконадежных и универсальных алгоритмов пока не существует.

Настоящая глава посвящена исследованию цифровых алгоритмов обработки радиолокационных изображений, представляющих собой объединение исследованных в предыдущих главах алгоритмов обнаружения и оценивания и специфических алгоритмов распознавания изображений [7–11]. Под радиолокационным изображением понимается двумерное представление радиолокационных сигналов, например, в координатах дальность – азимут, дальность – доплеровская частота, и т. п. Обработка такого изображения в конечном счете сводится к получению немногих обобщенных характеристик, т. е. эквивалентна сжатию радиолокационной информации.

Специфичность требований к сжатой (итоговой) информации состоит в том, что в результате анализа необходимо ответить на вопросы:

1. Обнаружена ли ПРЦ?
2. К какому классу целей (малозлементной, средней или многоэлементной) она относится?
3. Какими общегрупповыми параметрами она характеризуется?

В результате исследования алгоритмов распознавания, решающих поставленные выше задачи с учетом возможностей современной вычислительной техники, получены практические рекомендации по их реализации и выбору параметров.

8.1. Алгоритмы формирования цифровой модели радиолокационного изображения

Наблюдаемое радиолокационное изображение представляет собой двумерное декартово поле, координатами которого могут быть любые радиолокационные характеристики: наклонная дальность, доплеровская частота, угловые координаты и т. п., относящиеся к отражающим элементам. Радиолокационное поле разделяется на отдельные участки – дискреты разрешения, и абсолютные координаты отраженных сигналов могут быть заменены относительными номерами дискретов – по горизонтали – номером столбца, по вертикали – номером строки. Положение отраженных сигналов в радиолокационном поле определяется размерами и конфигурацией ПРЦ. Введем следующие предположения:

1. В одном дискрете разрешения может быть не более одного элемента ПРЦ.

2. При наличии отраженного сигнала в каком-либо дискрете его первичные радиолокационные характеристики соответствуют центру дискрета разрешения.

3. Как и ранее, в дальнейшем считаем, что отраженные от элементов ПРЦ сигналы обладают одинаковой средней мощностью.

Радиолокационная информация поступает на вход специализированной ЭЦВМ в виде отсчета амплитуды с выхода нелинейного устройства, осуществляющего операцию формирования статистики $\ln B(y/\tau_{ik})$ в моменты времени, соответствующие центру дискрета разрешения с координатами (i, k) .

8.1.1. Оптимальный алгоритм выделения сигнальных дискретов

Предположим, что выполняется неравенство

$$\frac{d}{dy} \left[\ln B \left(\frac{y}{\tau_{ik}} \right) \right] > 0, \quad i = \overline{1, n}, \quad k = \overline{1, m}, \quad (8.1.1)$$

которое означает математическую формулировку условия: большему по величине принятому отсчету соответствует большая вероятность того, что этот отсчет – сигнальный. Тогда, составив из всех принятых отсчетов вариационный ряд, для каждого из них можно ввести соответствующую

вероятность – меру принадлежности отсчета сигналу, которая постоянно убывает при увеличении его номера в этом ряду. Если точно известно число M отраженных сигналов, то, при условии равновероятности расположения элементов сложной цели на радиолокационном поле, выделение сигнальных дискретов состоит в записи в соответствующий массив координат M первых дискретов вариационного ряда. Полученная таким образом дискретная модель является максимально правдоподобной оценкой радиолокационного изображения ПРЦ. В том случае, когда вероятности P_{ik} , $i = \overline{1, L}$, $k = \overline{1, N}$ расположения элементов ПРЦ на радиолокационном поле неодинаковы, необходимо строить вариационный ряд на основании апостериорной вероятности, т. е. использовать для ранжирования величину $P_{ik} \ln B(y/\tau_{ik})$. Дискретная модель в этом случае является оценкой максимальной апостериорной вероятности. Незнание числа элементов сложной цели, не изменяя приведенных выше алгоритмов, требует введения дополнительного блока оценивания M . Критерий оценивания M и дискретной модели радиолокационного изображения должны совпадать. Отметим также, что при условии выполнения неравенства

$$\frac{d}{dy} \left[\ln B_{m_1} \left(\frac{y}{\tau_{ik}} \right) \right] > \frac{d}{dy} \left[\ln B_{m_2} \left(\frac{y}{\tau_{ik}} \right) \right] > 0, \quad m_1 > m_2, \quad (8.1.2)$$

где m_1 и m_2 – число элементов ПРЦ в дискрете разрешения.

Наиболее существенным недостатком приведенного оптимального алгоритма являются большие вычислительные затраты на его реализацию. Чтобы сравнить их, необходимо обратиться к квазиоптимальным алгоритмам.

8.1.2. Квазиоптимальный алгоритм выделения сигнальных элементов

При синтезе квазиоптимального алгоритма воспользуемся условием: в практически интересных случаях для получения качественных оценок отношение сигнал/шум не должно быть ниже некоторой величины. При этом условии число сигнальных дискретов редко достигает половины общего числа дискретов. Тогда оптимальный алгоритм выделения может быть заменен квазиоптимальным алгоритмом – поддискретным сравнением всех отсчетов с некоторым заранее выбранным порогом T . Здесь

наблюдается аналогия с алгоритмами обнаружения – оптимальным и выбором максимума (см. раздел 7.3).

Итак, квазиоптимальный алгоритм выделения сигнальных дискретов состоит в определении координат тех отсчетов, которые превысили порог T . Порог задается вероятностью ложной тревоги для одного дискрета разрешения.

Получим рекомендации по выбору порога. Назовем эталоном действительное расположение элементов ПРИЦ на радиолокационном поле, а образом – полученное в результате выделения на фоне шумов. Общее среднее число несовпадений $\overline{L}_S$ между эталоном и образом равно сумме среднего числа превышения $\overline{L}_{ш}$ порога T шумом и не превышений $\overline{L}_c$ сигналом + шумом:

$$\overline{L}_S = \overline{L}_{ш} + \overline{L}_c. \quad (8.1.3)$$

При использовании квазиоптимального алгоритма

$$\overline{L}_{ш} = (L - M)F; \quad (8.1.4)$$

$$\overline{L}_c = M(1 - D), \quad (8.1.5)$$

где L – общее число дискретов разрешения, $L = nm$; M – число сигналов; $D = 1 - \bar{D}$ – вероятность правильного обнаружения отраженного сигнала в одном дискрете.

На рис. 8.1 показаны зависимости среднего числа несовпадений $\overline{L}_S$ при $L = 500$, $M = 111$. Численные результаты получены путем статистического моделирования изображений при числе испытаний $Q = 100$ и $Q = 1000$. Графики отображают устойчивость результатов моделирования при $Q > 100$. При уменьшении F первое слагаемое уменьшается, доля его в $\overline{L}_S$ существенно падает и при $F < 10^{-3}$ его можно не учитывать. Это говорит о том, что при $L - M = 389$ и $F < 10^{-3}$ случайных превышений порога шумом практически не наблюдается.

Таким образом, величину

$$F_{ip} = (L - M)^{-1}. \quad (8.1.6)$$

следует принять за граничную вероятность ложной тревоги, выше которой ещё сколько-нибудь заметна величина $\overline{L}_ш$. Если $F < F_{гп}$, то L_s изменяется по экспоненциальному закону с показателем, равным

$$\frac{T}{1+g} = -\frac{\ln(F)}{1+g}.$$

Очевидно, при $g > -M\ln(F) = MT$ несовпадения между эталоном и образцом практически не наблюдаются.




Рис. 8.1. Зависимости числа несовпадений от отношения сигнал/шум




Рис. 8.2. Зависимости СКО числа несовпадений от отношения сигнал/шум

Определим вероятность ложной тревоги F_0 и, тем самым, порог T_0 , при которых для заданной величины g среднее число несовпадений минимально. Дифференцируя по T и решая полученное уравнение относительно T_0 и F_0 , получим:

$$T_0 = \frac{g}{1+g} \ln \frac{M}{(1+g)(L-M)}; \quad F_0 = \left(\frac{M}{(1+g)(L-M)} \right)^{\frac{g}{1+g}}. \quad (8.1.5)$$

При средних и больших отношениях сигнал/шум ($g > 10$ дБ) можно принять

$$F_0 \approx \frac{M}{(1+g)(L-M)} = \frac{M}{1+g} F_{\text{тп}}, \quad (8.1.6)$$

т.е. F_0 практически одного порядка с $F_{\text{тп}}$.

Введением различных весов для слагаемых в (8.1.3) можно определить показатель несоответствия эталона и образа

$$\overline{K_S} = c_1 \overline{L_{\text{ш}}} + c_2 \overline{L_c}. \quad (8.1.7)$$

Тогда выражения (8.7) можно записать в более общем виде:

$$T_0 = \frac{g}{1+g} \ln \frac{c_2 M}{c_1 (1+g)(L-M)}; \quad F_0 = \left(\frac{c_2 M}{c_1 (1+g)(L-M)} \right)^{\frac{g}{1+g}}. \quad (8.1.8)$$

Найдем зависимости среднеквадратичных ошибок (СКО) величины $\overline{L_S}$ от g . Поскольку $\overline{L_{\text{ш}}}$ и $\overline{L_c}$ статистически независимы и могут интегрироваться как результат соответствующего числа испытаний Бернулли, то дисперсия σ_{LS}^2 равна сумме дисперсий слагаемых:

$$\sigma_{LS}^2 = \sigma_{L_{\text{ш}}}^2 + \sigma_{L_c}^2 = (L-M) e^{-T} (1 - e^{-T}) + M e^{-T/(1+g)} (1 - e^{-T/(1+g)}). \quad (8.9)$$

Наибольшее значение СКО имеет при отношении сигнал/шум

$$\sigma_{\text{max}} = \frac{-\ln F}{\ln 2} = \frac{T}{\ln 2}. \quad (8.1.10)$$

При этом значение СКО

$$\sigma_{Ls_{\max}} = \left[(L - M) e^{-T} (1 - e^{-T}) + M/4 \right]^{1/2}. \quad (8.1.11)$$

Если $F < F_{\text{гр}}$ то первое слагаемое в (8.1.13) исчезает и максимальное значение СКО зависит только от числа элементов ПРЦ

$$\sigma_{Ls_{\max}} = \frac{\sqrt{M}}{2}. \quad (8.1.12)$$

При $F > F_{\text{гр}}$ СКО увеличивается незначительно (см. рис. 8.2.)

В заключение отметим, что чем больше элементов имеет сложная цель, тем меньше влияние разброса за счет шума на соответствие между образом и эталоном. Действительно, при правильно выбранных порогах относительное среднее число несовпадений $\frac{\overline{L_s}}{M} = 1 - F$ остается при увеличении числа элементов ПРЦ неизменным, а относительный разброс $\frac{\sigma_{Ls_{\max}}}{M} = \frac{2}{\sqrt{M}}$ при этом уменьшается.

8.2. Алгоритмы обработки цифровой модели радиолокационного изображения ПРЦ

В результате выделения сигнальных дискретов на радиолокационном изображении остается, как правило, небольшое число отсчетов. Поскольку средние мощности отраженных сигналов считаются одинаковыми, то можно отказаться от мешающей информации, закодированной в амплитуде отсчетов, и принять, что все сигнальные дискреты имеют некоторый фиксированный, например, единичный уровень. В этом случае цифровая модель радиолокационного изображения представляет собой совокупность нулевых и единичных дискретов (рис. 8.3). Ее обработка состоит в группировании единичных дискретов и последующем оценивании общегрупповых параметров.

8.2.1. Алгоритмы группирования

Для запоминания цифровой модели, состоящей из n строк и m столбцов, необходимо иметь $L = nm$ ячеек памяти. Поскольку в реальных ситуациях большинство дискретов нулевое, то, в целях экономии памяти,

необходимо запоминать лишь единичные дискреты. Алгоритм объединяет стоящие подряд в строке единичные дискреты и заносит в память номер строки, где расположена эта подгруппа, её начальный и конечный номера столбцов. Далее алгоритм группирует эти подгруппы, т. е. «собирает» из них группы.

Группа представляет собой совокупность единичных дискретов, являющихся либо соседями по столбцу, либо по строке. Например, на рис. 8.3 первая группа состоит из трех единичных дискретов (единиц), стоящих в первой строке в соседних столбцах. Точно также третья группа – это три соседних единицы во второй строке в пятом, шестом и седьмом столбцах. Пятая группа объединяет три соседние единицы, стоящие на различных строках и столбцах.

Такой алгоритм группировки является разновидностью алгоритма «ближайшего соседа» [7, 8] и означает следующее: если расстояние между центрами единичных дискретов не больше заранее заданной величины, то они должны быть отнесены к одной и той же группе

$$\Delta r_{a,b} = |r_a - r_b| \leq r_0. \quad (8.2.1)$$




Рис. 8.3. К определению алгоритма обработки цифровой модели радиолокационного изображения ПРЦ

В частности, если размер r_0 равен интервалу разрешения, то (8.2.1) превращается в условие «единичной связи» [7]:

$$(i_a - i_b)(j_a - j_b) = 0, \quad (8.2.2)$$

где i – номер строки; j – номер столбца дискрета с координатами (i, j) . Условие (8.16) является математической записью этого алгоритма группирования. Единичные дискреты с координатами (1,4) и (2,5) относятся

к различным группам – первой и третьей. Также в различные группы входят дискреты (4,11) и (5,12) (см. рис. 8.1).




Рис. 8.4. Эталонное изображение малого примера

Описанный алгоритм группирования безразличен к тому, какова внешняя граница группы, имеются ли внутри группы пустые области (много связность группы), он имеет меньшую зависимость времени обработки от количественных соотношений между группами и различными размерами. В этом состоит достоинство алгоритма (8.2.2) по сравнению с другими, предложенными, например, в [12].




Рис. 8.5. Эталонное изображение большого примера

Конкретная программная реализация описанного алгоритма осуществляется двумя путями. В первом случае используется алгоритм «единичной связи» (8.16) и специальные методы снижения вычислительных затрат (упакованное хранение информации, экономичные способы реализации алгоритма) [13, 14]. Программа ИЗОБР-1 приведена в [13]. Во втором случае в программе РІСТ-1 реализован алгоритм «ближайшего соседа» (8.15), а группирование осуществляется методами теории графов (используется дерево с минимальным покрытием) [13–17].

8.2.2. Алгоритм классификации и оценивания общегрупповых параметров

Сформированные группы разделяются на пять классов по числу входящих в них единичных дискретов:

- 1) первый класс – одиночные – один дискрет,
- 2) второй класс – малоразмерные – 2–4 дискрета,
- 3) третий класс – средние – 5–15 дискретов,
- 4) четвертый класс – большие – 16–50 дискретов,
- 5) пятый класс – сверхбольшие – свыше 50 дискретов.

Отношение максимального числа дискретов группы к минимальному для всех классов примерно одинаково и близко к трем. Естественно, указания классификации групп в достаточной степени условна, но она позволяет, во-первых, получить конкретные результаты анализа, большая часть которых справедлива при других методах групповой классификации, во-вторых, от пяти классов можно легко провести редукцию на меньшее число классов. Номер класса характеризует габаритные свойства группы и рассматривается в настоящей работе как один из общегрупповых параметров.

Вторым общегрупповым параметром является «центр тяжести» группы, координаты которого определяются по формулам

$$r_y = \frac{1}{M_{\text{гр}}} \sum_{i=i_{\min}}^{i_{\max}} i k_i; \quad r_x = \frac{1}{M_{\text{гр}}} \sum_{j=j_{\min}}^{j_{\max}} j k_j, \quad (8.2.3)$$

где $M_{\text{гр}} = \sum k_i$ – общее число элементов группы; k_i – число элементов в i -ой строке; k_j – число элементов в j -м столбце; $i_{\min}, i_{\max}, j_{\min}, j_{\max}$ – «габариты» группы.

Согласно (8.2.3), первая группа на рис. 8.3 имеет координаты второго параметра $r_x = 1, r_y = 3$, т. е. (1,3), а четвертая группа – $\left(3\frac{2}{3}, 9\frac{2}{3}\right)$. Отметим, что «центр тяжести» последней группы приходится на несигнальный (нулевой) элемент разрешения. Вычисление отклонений второго общегруппового параметра состоит в определении расстояний между «центрами тяжести» эталонной и ближайшей из обнаруженных групп, выраженных в дискретах разрешения.

Таким образом, оба общегрупповых параметра фиксируют наиболее существенные характеристики группы – размер и местоположение – и с этой точки зрения представляют наибольший интерес как в тактическом отношении, так и для последующих этапов обработки радиолокационных сигналов ПРЦ.

8.3. Анализ результатов статистического моделирования алгоритмов оценивания общегрупповых параметров ПРЦ

Алгоритмы оценивания, описанные выше, были исследованы в [13, 14] на двух примерах – малом (рис. 8.4) и большом (рис. 8.5) – построения эталона радиолокационного изображения при двух видах распределений амплитуд отраженных сигналов: релеевском (5.23) и обобщенном релеевском (5.24) на входе квадратичного детектора. В обоих примерах заданы по одной группе каждого класса, в зачерненных дискретах радиолокационный сигнал равен сумме отраженного сигнала и шума, а пустых – только одного шума. Вследствие приемлемых затрат машинного времени малый пример анализировался в более широком диапазоне изменения параметров, чем большой. Как правило, число испытаний Q было равно 100, в некоторых случаях оно выбиралось в 10 раз больше. Сравнение результатов, полученных в том и другом случае, привело к выводу, что при $Q = 100$ усредненные по числу испытаний характеристики алгоритмов оценивания общегрупповых параметров найдены с точностью, достаточной для проведения последующего анализа. На всех рисунках графики изображены в виде ломанных линий, состоящих из отрезков прямых, соединяющих вычисленные в эксперименте точки. Этот прием позволяет получить более наглядное графическое изображение исследуемых зависимостей при ограниченном числе экспериментальных точек.

При анализе алгоритмов оценивания общегрупповых параметров использовались следующие характеристики групп и классов:

1. Абсолютные $\bar{N}_l, l = \overline{1,5}$ и относительные $\bar{N}_{гр_l} = \bar{N}_l / N_{гр_l}, l = \overline{1,5}$, средние значения числа обнаруженных групп в каждом классе.
2. Вероятность необнаружения $\bar{P}_l$ групп l -го класса.
3. Среднее отклонение Δr_l общегруппового параметра обнаруженной группы l -го класса от действительного параметра, задаваемого эталоном.
4. Среднее число $M_{лl}$ ненулевых дискретов группы l -го класса.

5. Среднее число несовпадений $\overline{L}_s$ дискретов разрешения между эталоном и образом (см. пункт 8.1.2).


8.3.1. Сравнение оптимального и квазиоптимального алгоритмов выделения сигнальных дискретов

Оптимальный алгоритм синтезирован для выделения всей совокупности сигнальных дискретов, и в этом смысле он придает каждому из них одинаковые веса (см. условие 1 параграфа 8.1). При группировании эта равноценность дискретов приводит к неодинаковому участию групп различных классов в общей статистике оценивания числа сигнальных дискретов, определяемого числом дискретов групп. Следовательно, оптимальный алгоритм выделения сигнальных дискретов в большей степени настроен на распознавание групп старших классов. Однако, выбрав некоторое значение вероятной ложной тревоги F^* , близкое к F_0 , можно получить более качественные характеристики распознавания групп младших (первого, второго, частично третьего) классов, если в некоторой мере снизить требования к качеству распознавания групп старших классов. С увеличением отношения сигнал/шум влияние подобного приема на характеристики уменьшается и уже при $g > 15$ дБ оно практически незаметно. Эти общие положения наглядно иллюстрируются рис. 8.6, на котором представлены результаты моделирования обоих алгоритмов при обработке образа малого примера. Следует отметить, что время моделирования при использовании оптимального алгоритма в 11,3 раза больше, чем квазиоптимального. Во втором случае величина F выбрана такой, которая обеспечивает наилучшее качество распознавания групп всех классов.


Сравнение графиков зависимостей приводит к следующим выводам:

а) применение оптимального алгоритма выделения сигнальных дискретов может быть рекомендовано при распознавании групп старших классов, то есть ПРЦ с числом элементов более 5–10, при малых отношениях сигнал/шум ($g < 10$ дБ). При этом межгрупповое расстояние должно быть задано в диапазоне (2–3) дискрета;

б) в остальных случаях необходимо использовать квазиоптимальный алгоритм выделения сигнальных дискретов при соответствующих значениях вероятности ложной тревоги F^* и межгрупповом расстоянии r_0^* .



а



б

Рис. 8.6. Сравнение характеристик оценивания числа групп при различных межгрупповых расстояниях:
а — $r_0 = 1$; б — $r_0 = 2,5$

Итак, наибольший практический интерес представляют характеристики оценивания квазиоптимального алгоритма, результаты анализа и рекомендации по выбору параметров F^* и r_0^* которого приводятся ниже.

8.3.2. Характеристики оценивания при использовании квазиоптимального алгоритма выделения сигнальных дискретов и релейевской модели отраженного сигнала

На рис. 8.7 представлены зависимости вероятности необнаружения групп различных классов в малом примере для крайних значений вероятностей ложной тревоги $F = 10^{-1}$ и $F = 10^{-6}$ ($r_0 = 1$).




Рис. 8.7. Зависимости вероятности необнаружения групп в малом примере от отношения сигнал/шум




Рис. 8.8. Зависимости вероятностей необнаружения групп от вероятности ложной тревоги в малом примере

Группы, относящиеся к более старшему классу, обнаруживаются, в основном, хуже по сравнению с группами младших классов. При малых $F \ll F_{\text{гр}}$ увеличение отношения сигнал/шум g приводит к тому, что величина D возрастает, но для групп младших классов от 10 до 15 дБ происходит ухудшение обнаружения. При таких отношениях сигнал/шум начинают обнаруживаться группы старших классов (четвертого и пятого), которые ранее, при малых g , были раздроблены и воспринимались как группы младших классов. При уровне g выше 15 дБ все классы имеют тенденцию к улучшению качества обнаружения.

Для больших вероятностей ложной тревоги ($F > F_{\text{гр}}$) младшие классы хорошо обнаруживаются во всем диапазоне отношений сигнал/шум, а все классы – начиная с уровня 8–9 дБ. Отличительной особенностью этого случая является не очень высокое качество обнаружения групп третьего класса. Для всех вероятностей ложных тревог $10^{-1} \leq F \leq 10^{-6}$ группы пятого класса, начиная с некоторого g , обнаруживаются с вероятностью, близкой к единице, например, при $F = 10^{-1}$ – с 10 дБ и выше, а при $F = 10^{-6}$ – с 15 дБ.

Зависимости вероятности необнаружения групп от уровня F при фиксированном отношении сигнал/шум $g = 5$ дБ, представленные на рис. 8.8 также показывают увеличивающуюся с возрастанием номера класса вероятность необнаружения. При малых F появляются случаи необнаружения групп даже первого класса. При больших F группы пятого класса обнаруживаются лучше, чем группы четвертого класса. Это происходит вследствие большого числа шумовых ненулевых элементов разрешения, которые объединяются в группы сверхбольшого размера. Теснота расположения групп на информационном поле приводит к тому, что некоторые группы объединяются за счет ненулевых шумовых элементов и переходят в другой класс. Следовательно, вероятность ложных тревог F^* для малого примера должна быть не выше $F_{\text{гр}}$, в противном случае группы старших классов обнаруживаются за счет групп младших классов. К аналогичному выводу приводит анализ характеристик оценивания в большом примере.

Разница в пороговом сигнале при одних и тех же условиях обнаружения наиболее значительна между первым и вторым классами, на уровне $D = 0,8$, $F = 10^{-6}$ она равна (5–6 дБ). Чуть меньше различие наблюдается между вторым и третьим, а также четвертым и пятым классами.

Определенный интерес вызывают зависимости вероятности необнаружения групп от номера класса, построенные для малого примера на рис. 8.9. При малых отношениях сигнал/шум (0–5 дБ) наблюдается в среднем ухудшающееся качество обнаружения групп с возрастанием номера класса (от единицы для первого до нуля для пятого). При средних и больших отношениях сигнал/шум наиболее примечательно плохое качество обнаружения групп четвертого класса. Например, при $g \sim (10\text{--}15)$ дБ вероятность обнаружения группы четвертого класса равна 0,4, а при $g \sim (15\text{--}20)$ дБ – 0,8, в то время как другие классы имеют вероятность обнаружения не хуже 0,95 (рис. 8.9, а).




Рис. 8.9. Зависимости вероятности необнаружения группы от номера класса в малом примере:
а – $F = 10^{-2}$; б – $F = 10^{-4}$

При уменьшении вероятности ложной тревоги с 10^{-2} до 10^{-4} (см. рис. 8.9, б) четвертый класс уже не так выделяется на фоне других классов, особенно для больших и малых отношений сигнал/шум. Значительно хуже обнаруживаются группы первого класса, происходит естественный сдвиг всех зависимостей влево от старших классов к младшим.

Отличие большого примера от малого состоит в том, что в этом случае при тех же параметрах наихудшим качеством обнаружения обладают группы третьего класса. Такой переход от четвертого к третьему классу объясняется гораздо меньшим влиянием межгрупповых расстояний в большом примере на группировку ненулевых дискретов при $F > F_{гр}$.

При уменьшении вероятности ложной тревоги ($F < F_{гр}$) этот эффект, как и в малом примере, исчезает. Таким образом, вероятность обнаружения группы существенно зависит от вероятности ложной тревоги для одиночного сигнала, которая должна выбираться не больше $F_{гр}$. В противном случае резко уменьшается вероятность обнаружения групп третьего и четвертого, т.е. средних классов. Если же $F < F_{гр}$, то, как правило, наихудшее качество обнаружения при средних отношениях сигнал/шум имеют группы первого и четвертого-пятого классов. При малых отношениях сигнал/шум $g = 0-10$ дБ группа обнаруживается тем хуже, чем больше номер ее класса, при больших ($g > 20$ дБ) – группы всех классов обнаруживаются практически всегда.

Рассмотрим, как влияют параметры обнаружения F и g на количество обнаруживаемых групп в обоих примерах. В малом примере при $F > F_{гр}$ число обнаруженных групп первого и второго классов велико и с возрастанием отношения сигнал/шум ниже некоторых значений не уменьшается. Для первого класса это значение равно 15,6, для второго – 4,8, для третьего – 1,5 (рис. 8.10). Поскольку дополнительные группы возникают при больших g только за счет шума, то можно сказать, что примерно половина шумовых ненулевых отсчетов, среднее число которых в этом случае равно 38,9, идет на формирование групп первого класса, столько же – на формирование групп второго класса и примерно 10% – на группы третьего класса. По этой же причине СКО числа таких групп не зависит от g , как это показано на рис. 8.11 ($F = 10^{-1}$) штриховыми линиями. Даже число групп четвертого класса при такой большой ложной тревоге имеет смещенное выборочное среднее, а его СКО также постоянно при больших g . Группы пятого класса обнаруживаются точно, начиная с $g = 10$ дБ. При малых отношениях сигнал/шум наибольшее число групп имеют младшие классы, а наименьшее – старшие классы.

При $F < F_{гр}$ резко изменяется количество обнаруженных групп и их зависимость от отношения сигнал/шум. Для первого класса при $g = 5$ дБ оно уменьшается, например в 2,5 раза. Начиная с $g = 10$ дБ при его дальнейшем увеличении число групп стремится к истинной величине, а при $g > 15$ дБ оно практически равно ей для всех классов, кроме четвертого (см. рис. 8.10). СКО среднего числа групп также стремится в этом случае ($F = 10^{-4}$) к своему асимптотическому значению – нулю – и при $g > 15$ дБ не превышает 0,8, а при $g > 20$ дБ – 0,3.




Рис. 8.10. Зависимости среднего числа групп в классе от отношения сигнал/шум в малом примере




Рис. 8.11. Зависимости СКО среднего числа групп в классе от отношения сигнал/шум в малом примере

Наибольшее лишнее число групп обнаруживается при отношениях сигнал/шум от 5 до 10 дБ. В этом диапазоне алгоритмам группирования и классификации работать наиболее трудно: вследствие небольшого отношения сигнал/шум группы четвертого и пятого классов обнаруживаются плохо, они дробятся на отдельные небольшие скопления, которые воспринимаются алгоритмом как группы меньших классов,

группы третьего и второго классов по этой же причине обнаруживаются как группы второго или первого класса или вообще не обнаруживаются. Происходит переход групп из того класса, к которому они действительно принадлежат, к классам меньших номеров, что приводит к перепутыванию и наложению характеристик обнаружения и классификации. Подобное явление будет наблюдаться при любой вероятности ложной тревоги $F^* < F_{\text{гр}}$, но при различных отношениях сигнал/шум, особенно для первого класса.

Этот вывод подтверждается зависимостями среднего числа групп в классе от отношения сигнал/шум в большом примере, изображенными на рис. 8.12. Здесь при уменьшении F с 10^{-4} до 10^{-6} отношение сигнал/шум, при котором число групп первого класса максимально, увеличилось с 5 дБ до 10 дБ, причем само это максимальное число изменилось незначительно – с 9,5 до 8,2. На других классах уменьшение F сказалось еще в меньшей степени. Отметим, что максимальное число групп как первого, так и второго классов при одинаковой вероятности ложной тревоги ($F = 10^{-4} < F_{\text{гр}}$) для малого и большого примеров остается примерно одинаковым, соответственно 7,8 и 9,5, 3,0 и 4,8, хотя общие размеры радиолокационного изображения увеличились в 6 раз.

Таким образом, при $F < F_{\text{гр}}$ среднее число обнаруженных групп практически не зависит от размеров радиолокационного изображения и целиком определяется при малых и средних отношениях сигнал/шум размерами и конфигурацией групп. Изменение F в диапазоне $(0, F_{\text{гр}})$ почти не сказывается на количественных соотношениях между средним числом m групп обнаруживаемых классов, приводя лишь к смещению по оси отношений сигнал/шум характеристики оценивания. Следовательно, выбор очень низкой вероятности ложной тревоги с точки зрения наилучшего соответствия числа обнаруженных групп действительному не оправдан. Величина её должна быть примерно одного порядка с $F_{\text{гр}}$.

Рассмотрим зависимости средней ошибки определения общегруппового параметра Δr , представляющего, как было сказано ранее, отклонение от центра тяжести группы, от отношения сигнал/шум и номера класса. Величина Δr на графиках имеет размерность дискрета разрешения. Приведенные на рис. 8.14 характеристики говорят о том, что при большой вероятности ложной тревоги $F > F_{\text{гр}}$ и увеличении отношения сигнал/шум ошибка

$\overline{\Delta r}$ у групп всех классов не уменьшается, а у некоторых классов даже возрастает. Не уменьшается с увеличением сигнал/шум и СКО средней ошибки, например, его значение велико (даже аномально) у групп второго класса. Шумовые выбросы при большой ложной тревоге, помогая раньше обнаружить группы, не позволяют достаточно точно определить их местоположение.




Рис. 8.12. Зависимости среднего числа групп в классе от отношения сигнал/шум в большом примере




Рис. 8.13. Зависимости средней ошибки определения общегруппового параметра от отношения сигнал/шум в большом примере

Уменьшение вероятности ложной тревоги ($F < F_{гр}$), приводит, естественно, к резкому возрастанию средних ошибок определения общегруппового параметра $\overline{\Delta r}$ при малых отношениях сигнал/шум. Однако в этом случае существенно уменьшаются ошибки $\overline{\Delta r}$ при больших отношениях сигнал/шум.

Например, при $F = 10^{-4}$ и $g = 15$ дБ величина $\overline{\Delta r} < 0,35$, а при $g = 20$ дБ практически равна нулю для всех классов, т. е. местоположение групп определяется точно. Этот вывод также подтверждают зависимости СКО при $F = 10^{-4}$, показанные на рис. 8.15 сплошными линиями, сходящимися практически к нулю при $g \geq 20$ дБ. Дальнейшее уменьшение F ($F \ll F_{гр}$) не приводит к существенному изменению зависимости средних ошибок $\overline{\Delta r}$, лишь в небольшой степени поднимая их на одинаковую величину при всех отношениях сигнал/шум.




Рис. 8.14. Зависимости средней ошибки определения общегруппового параметра от отношения сигнал/шум в малом примере

Сравнение малого (см. рис. 8.14) и большого (см. рис. 8.13) примеров приводит к следующим общим выводам: при $F < F_{гр}$ группы первого класса обнаруживаются на своих действительных местах достаточно точно при отношениях сигнал/шум $g > 15$ дБ ($\overline{\Delta r} < 1,2$), группы второго, третьего и четвертого классов – начиная с 10 дБ ($\overline{\Delta r} < 2$), а группы пятого

класса – с 15 дБ. Пятый класс отличается тем, что, если группы этого класса обнаружены, то это наверняка группы пятого класса с тем же самым общегрупповым параметром. Таким образом, и с точки зрения наименьшей ошибки в определении общегруппового параметра вероятность ложной тревоги F должна быть ниже $F_{гр}$ и не очень существенно отличаться от неё. При выполнении этого условия группы всех классов имеют ошибку Δr при $g = 15$ дБ меньше 1,7, при $g = 20$ дБ – меньше 0,8 дискрета.




Рис. 8.15. Зависимость СКО определения общегруппового параметра от отношения сигнал/шум в малом примере

Границами изменения величины r_0 в алгоритме «ближнего соседа» являются единица и минимальное межгрупповое расстояние, которое априори, как правило, неизвестно. Выбор того или иного значения r_0^* в этом диапазоне при соответствующем подборе вероятности ложной тревоги F^* практически не сказывается на характеристиках оценивания. Поэтому, не рассматривая подробно результаты исследований, приведем окончательные рекомендации по выбору параметров F_M^* и r_{0M}^* в малом примере (табл. 8.1). При анализе других изображений переход должен выполняться по формулам

$$F^* = F_M^* \frac{F_{гр}}{F_{грM}}; \quad r_0^* = r_{0M}^*. \quad (8.3.1)$$

Таблица 8.1

Настраиваемые параметры квазиоптимального
алгоритма выделения ПРЦ

Межгрупповое расстояние, r_0^*	Отношение сигнал/шум (дБ)	Распознаваемые классы	Вероятность ложной тревоги F^*
1	10	3–5	$(5,0–8,9)10^{-2}$
	15	2–5	$(6,5–11)10^{-3}$
	20	1–5	$(0,5–7,0)10^{-4}$
1,5	10	3–5	$(2,2–7,8)10^{-2}$
	15	2–5	$(1,3–3,0)10^{-3}$
	15	1–5	$(0,5–1,0)10^{-3}$
	20	1–5	$(0,5–3,0)10^{-4}$
2	10	3–5	$(1,1–5,9)10^{-2}$
	15	2–5	$(1,0–7,0)10^{-3}$
	20	1–5	$(3,0–7,0)10^{-5}$
2,5	10	3–5	$(1,1–3,3)10^{-2}$
	15	2–5	$(0,7–7,0)10^{-3}$
	15	1–5	$(1,0–5,0)10^{-5}$
	20	2–5	$(1–11)10^{-3}$
	20	1–5	$(0,7–3,0)10^{-4}$
	20	1–5	$(0,1–7,0)10^{-5}$

8.3.3. Влияние когерентной составляющей в отраженном сигнале на характеристики оценивания

Если отраженный сигнал, помимо диффузной, имеет когерентную составляющую, то амплитуда его огибающей распределена по обобщенному релеевскому закону. Величина, обозначенная далее a , и характеризующая уровень когерентности, определяется соотношением (5.20). Значения a принимаются равными 1, 2 и 5. В частности, при $a = 5$ амплитуда отраженного сигнала практически распределена по нормальному закону.

Как и при релеевском распределении, в данном случае также имеется такое значение вероятности ложной тревоги F_0 (естественно зависящее

от r_0), при котором число несовпадений $\overline{L_S}$ между эталоном и образом минимально. Для определения $\overline{L_S}$ следует использовать выражение (8.7), учитывая, что вероятность превышения порога T сигналом + шумом равна

$$D = \frac{1}{2\sigma^2} \int_T^\infty \exp\left\{-\frac{A^2 + \alpha^2\sigma^2}{2\sigma^2}\right\} I_0\left(\frac{aA}{\sigma}\right) dA, \quad (8.3.2)$$

где $2\sigma^2$ – мощность диффузной составляющей.

Результаты статистического моделирования показывают, что при высоких вероятностях ложных тревог ($F \gg F_{\text{гр}}$) увеличение уровня когерентности в отраженном сигнале приводит к безусловному уменьшению $\overline{L_S}$. При вероятностях, близких к $F_{\text{гр}}$, возрастание a вызывает увеличение $\overline{L_S}$ при малых и резкое уменьшение при средних и больших отношениях сигнал/шум. В последнем случае качество обнаружения и оценивания радиолокационного изображения с увеличением величины непрерывно улучшается. При очень малой вероятности ложной тревоги ($F \ll F_{\text{гр}}$) влияние параметра a сказывается, в основном, только при больших отношениях сигнал/шум.

Отметим, что при $g < 10$ дБ вероятность обнаружения групп младших классов с увеличением a уменьшается, а старших классов – возрастает, причем, чем больше, тем существеннее (рис. 8.16 и 8.17). Следовательно, если имеется возможность влияния на уровень когерентности отраженного сигнала, то с точки зрения наибольшей вероятности обнаружения групп следует выбирать величину a максимальной при $g > 10$ –15 дБ и, наоборот, минимальной (использовать только диффузное отражение) при $g < 10$ дБ (рис. 8.18). Этот вывод справедлив при вероятностях ложных тревог $F < F_{\text{гр}}$. Если $F > F_{\text{гр}}$, то величина a практически не влияет на вероятность обнаружения групп.

Влияние уровня когерентности на значение отклонений в определении «центра тяжести» групп носит аналогичный характер (рис. 8.19): при $g > 15$ дБ и $a = 5$ местоположение групп всех классов определяется практически точно, а при $g > 18$ дБ в малом примере из 100 испытаний не было ни одного отклонения образа от эталона ни в одном из 500 дискретов разрешения.

Итак, при больших вероятностях ложной тревоги ($F > F_{\text{гр}}$) алгоритмы безразличны к уровню когерентности отраженного сигнала. При малых

вероятностях ложной тревоги ($F < F_{гр}$) влияние величины a двояко: при малых отношениях сигнал/шум (10–15 дБ) возрастание a ухудшает характеристики обнаружения и оценивания, при средних и больших – улучшает их.




Рис. 8.16. Зависимости вероятности необнаружения группы от номера класса в большом примере




Рис. 8.17. Зависимости вероятности необнаружения группы от номера класса в малом примере




Рис. 8.18. Зависимости вероятности необнаружения группы от отношения сигнал/шум в большом примере




Рис. 8.19. Зависимости средней ошибки определения общегруппового параметра от отношения сигнал/шум в большом примере

8.4. Литература к главе 8

1. Справочник по радиолокации / М. Сколник и др.: Пер. с англ. Под ред. К.Н. Трофимова. Т. 4. Радиолокационные станции и системы. М.: Советское радио. 1978. 376 с.
2. Ван Трис Г. Теория обнаружения, оценок и модуляции / Г. Ван Трис: пер. с англ. Т. 3. Обработка сигналов в радио- и гидролокации и приём случайных гауссовых сигналов на фоне помех / под ред. В.Т. Горяинова. М.: Советское радио, 1977. 663 с.
3. Кузьмин С.З. Основы теории цифровой обработки радиолокационной информации / С.З. Кузьмин. М.: Советское радио, 1974. 432 с.
4. Слока В.К. Вопросы обработки радиолокационных сигналов / В.К. Слока. М.: Советское ради, 1970. 256 с.
5. Лихарев В.А. Цифровые методы и устройства в радиолокации / В.А. Лихарев. М.: Советское радио, 1973. 456 с.
6. Моделирование в радиолокации / А.И. Леонов, В.Н. Васенев, Ю.И. Гайдуков и др.; под ред. А.И. Леонова. М.: Советское радио, 1979. 244 с.
7. Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт; Пер с англ. М.: Мир, 1976. 511 с.
8. Патрик Э. Основы теории распознавания образов / Э. Патрик; пер с англ. под ред. Б.Р. Левина. М.: Советское радио, 1980. 408 с.
9. Ковалевский В.А. Методы оптимальных решений в распознавании изображений / В.А. Ковалевский. М.: Наука, 1976. 328 с.
10. Розенфельд А. Распознавание и обработка изображений с помощью вычислительных машин / А. Розенфельд ; пер с англ. М.: Мир, 1972. 230 с.
11. Загоруйко Н.Г. Методы распознавания и их применение / Н.Г. Загоруйко. М.: Советское радио, 1972. 206 с.
12. Обобщённая вторичная обработка радиолокационной информации / Я.А. Фурман, И.П. Цивлин // Обработка сигналов от распределённых целей при гауссовых и негауссовых помехах: Тр. межведом. семинара. Свердловск, 1977. С. 21-22.
13. Оптимальное обнаружение-оценивание групповой цели в условиях априорной неопределённости // Вестн. УГТУ-УПИ. Проект. и анализ радиотехн. и инф. систем. Серия радиотехн. № 21 (71). Екатеринбург: ГОУ ВПО УГТУ-УПИ, 2005, С. 69-74.

14. Анализ алгоритма «единичной связи» для автоматической группировки деталей изображения / Л.Г. Доросинский, М.П. Трухин. В кн.: Проблемы повышения эффективности и качества радиотехнических систем. Вып. 2. Свердловск: Изд-е УПИ, 1979. С. 47-50.

15. Эффективные методы рекуррентного формирования оптимальной статистики обнаружения групповой цели / М.П. Трухин, С.И. Тимошенко / Деп. в ВИНТИ, 1988. № 847-В 88.

16. Анализ показателей эффективности обнаружителей-измерителей параметров групповой цели при использовании сложных ФМ-сигналов / М.П. Трухин, Л.Т. Меведева / В кн.: Всесоюзн. конф. по распредел. объектам. Свердловск: изд-е УПИ, 1989.

17. Оптимальное обнаружение-оценивание групповой цели в условиях априорной неопределённости Вестник ГОУ ВПО УГТУ-УПИ. Проектирование и анализ радиотех. и инф. систем. Серия радиотехн. №21 (71). Екатеринбург: ГОУ ВПО УГТУ-УПИ, 2005, С. 69-74.

9. ОСОБЕННОСТИ ПОЛУЧЕНИЯ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ДВИЖУЩИХСЯ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЕННЫХ ЦЕЛЕЙ

9.1. Искажение РЛИ при движении ПРЦ

Сложный характер движения пространственно-распределенной цели (ПРЦ) приводит к тому, что закон изменения фазы отраженного сигнала от каждого элемента цели и весовая функция обработки, призванная повторить этот закон при синтезе радиолокационного изображения (РЛИ), существенно отличаются, что, в свою очередь, приводит к искажениям, как радиолокационного изображения цели, формируемого в данном конкретном наблюдении, так и радиолокационного портрета ПРЦ, представляющего собой основу для формирования банка (базы) данных радиолокационных портретов (РП) ПРЦ. Возможные варианты таких искажений, вызванные движением цели в течение времени наблюдения, рассмотрены в данной работе.

Введем модель сигнала, принимаемого РЛС. Будем считать радиолокационные станции, входящие в систему наблюдения, в общем случае бистатистическими²⁴. Принимаемый отраженный сигнал представим в виде вектора комплексных амплитуд $\bar{U}(t)$, для составляющих которого справедливо выражение:

$$\begin{aligned}\bar{U}(t) = U_k \int_{\Omega_k} f_k(\bar{x}) \frac{g_1(\bar{x}, t) g_2(\bar{x}, t)}{r_1(x, t) r_2(x, t)} s \left\{ t - \frac{[r_1(\bar{x}, t) + r_2(\bar{x}, t)]}{c} \right\} \times \\ \times \exp \left\{ -j k [r_1(\bar{x}, t) + r_2(\bar{x}, t)] \right\} d\bar{x} + N(t).\end{aligned}$$

В приведенном выражении $g_1(\bar{x}, t)$, $g_2(\bar{x}, t)$ – значения нормированных диаграмм направленности передающей и приемной антенн РЛС в направлении точки цели $\bar{x}$ в момент времени t ; $r_1(\bar{x}, t)$, $r_2(\bar{x}, t)$ – текущее значение дальности от передатчика и приемника РЛС до точки $\bar{x}$ цели;

²⁴ Передатчик и приемник размещены на разных носителях.

$S(t)$ – комплексная амплитуда модулирующей функции зондирующего сигнала, которую в дальнейшем считаем импульсной с длительностью импульса τ и периодом повторения T и нормированной таким образом, что выполняется условие:

$$\frac{1}{\tau} \int |s(t)|^2 dt = 1$$

$N(t)$ – комплексная амплитуда аддитивного шума радиолокационного тракта; $k = \frac{2\pi}{\lambda}$ – волновое число.

Время наблюдения цели ограничено и равно T .

Введем обозначения, где

$$G(\bar{x}, t) = \frac{g_1(\bar{x}, t) g_2(\bar{x}, t)}{r_1(x, t) r_2(x, t)};$$

$$S(\bar{x}, t) = s \left\{ t - \frac{[r_1(\bar{x}, t) + r_2(\bar{x}, t)]}{c} \right\};$$

$$E(\bar{x}, t) = \exp \left\{ -jk [r_1(\bar{x}, t) + r_2(\bar{x}, t)] \right\}$$

и определим функцию неопределенности траекторного сигнала при формировании РЛИ ПРЦ:

$$\begin{aligned} \varphi(\bar{p}_x, \bar{p}_z) = \int & \left[E\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) S^*\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) G\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) \times \right. \\ & \left. \times G(\bar{p}_z, t) S(\bar{p}_z, t) E(\bar{p}_z, t) \right] dt, \end{aligned} \quad (9.1.1)$$

где $E\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right)$, $S\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right)$, $G\left(\bar{p}_x, \frac{t}{\bar{x}^0}, \bar{x}\right)$ – матрицы, описывающие ожидаемый траекторный сигнал от точки цели, положение которой относительно центра НК в основной системе координат характеризуется вектором $\bar{p}_x$; $E(\bar{p}_z, t)$, $S(\bar{p}_z, t)$, $G(\bar{p}_z, t)$ – матрицы, задающие принимаемый траекторный сигнал от точки с координатой $\bar{p}_z$. Использование функции неопределенности в виде (9.1.1) позволяет не только определить свойства

РЛИ при оптимальном его построении (то есть при полностью известных законах движения как ПРЦ, так и носителя РСА), но и оценить возможные искажения изображения цели, вызванные априорной неопределенностью относительно параметров взаимного перемещения НК и РСА.

При использовании импульсного сигнала

$$S(t) = \sum_{n=-N}^{N_p} S(t-nT), \quad (9.1.2)$$

где $(2N+1)$ – общее число импульсов, отраженных от цели, и предположении о неизменности за время, равное длительности импульса, следующих функций:

$$E\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) = \text{const}; \quad E(\bar{\rho}_z, t) = \text{const};$$

$$G\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) = \text{const}; \quad G(\bar{\rho}_z, t) = \text{const}$$

получим:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-N}^N \sum_{m=-N}^N E^*\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) E(\bar{\rho}_z, t) \times \\ & \times G\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) G(\bar{\rho}_z, t) \times \\ & \times \int_{S_0}^* \left[t - nT \frac{r_1\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) - r_2\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right)}{C} \right] \times \\ & \times S_0 \left[t - mT \frac{r_1\left(\bar{\rho}_z, \frac{t}{\bar{x}^0}, \bar{x}\right) - r_2\left(\bar{\rho}_z, \frac{t}{\bar{x}^0}, \bar{x}\right)}{C} \right] dt, \end{aligned} \quad (9.1.3)$$

$$\text{где} \quad t_n = t_{0p} + nT; \quad (9.1.4)$$

$r_1\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right), r_2\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right)$ – ожидаемые законы изменения расстояний от точки, задаваемой радиусом-вектором $\bar{\rho}_x$, до передающей и приемной

РЛС соответственно, $r_1(\bar{\rho}_z, t)$, $r_2(\bar{\rho}_z, t)$ – истинные законы изменения расстояний от точки $\bar{\rho}_z$ до передающей и приемной РЛС.

Поскольку значение периода повторения T выбирается с учетом условия однозначного измерения дальности в пределах зоны обзора, интеграл в (9.1.3) обращается в нуль для неравных значений n и m . Следовательно:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-N}^N G\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) G(\bar{\rho}_z, t) \times \\ & \times E^*\left(\bar{\rho}_x, \frac{t}{\bar{x}^0}, \bar{x}\right) E(\bar{\rho}_z, t) \varphi_n^D(\bar{\rho}_x, \bar{\rho}_z), \end{aligned} \quad (9.1.5)$$

$$\begin{aligned} \text{где} \quad \varphi_n^D(\bar{\rho}_x, \bar{\rho}_z) = & \int S_0 \left[t - nT - \frac{r_1(\bar{\rho}_z, t) - r_2(\bar{\rho}_z, t)}{C} \right] \times \\ & \times S_0^* \left[t - nT - \frac{r_1\left(\bar{\rho}_z, \frac{t}{\bar{x}^0}, \bar{x}\right) - r_2\left(\bar{\rho}_z, \frac{t}{\bar{x}^0}, \bar{x}\right)}{C} \right] dt; \end{aligned} \quad (9.1.6)$$

– функция неопределенности одиночного зондирующего импульса. Поскольку РЛИ формируется только в окрестности цели, размеры которой существенно меньше любой из дальностей $r_1(\rho, t)$ и $r_2(\rho, t)$, выражение (9.1.5) можно упростить, полагая

$$\langle G\left(\bar{\rho}, \frac{t_n}{\bar{x}^0}, \bar{x}\right) = G(\bar{\rho}, t_n) = \frac{g_1(t_n)g_2(t_n)}{r_1^0(t_n)r_2^0(t_n)}, \quad (9.1.7)$$

где $g_1(t_n)$ и $g_2(t_n)$ – значения нормированных ДН передающей и приемной антенн в направлении на центр цели в момент излучения n -го импульса. $r_1^0(t_n)$ и $r_2^0(t_n)$ – дальности от передатчика и приемника до центра цели. С учетом (7) выражение (5) может быть представлено в виде:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-M}^M \left[\frac{g_1(t_n)g_2(t_n)}{r_1^0(t_n)r_2^0(t_n)} \right]^2 \times \\ & \times \exp \left\{ Jk \left[r_1\left(\bar{\rho}_x, \frac{t_n}{\bar{x}^0}, \bar{x}\right) + r_2\left(\bar{\rho}_x, \frac{t_n}{\bar{x}^0}, \bar{x}\right) - \right. \right. \\ & \left. \left. - r_1(\bar{\rho}_z, t_n) - r_2(\bar{\rho}_z, t_n) \right] \right\} \varphi_n(\bar{\rho}_x, \bar{\rho}_z). \end{aligned} \quad (9.1.8)$$

Дополнительного упрощения можно достичь, предполагая сомножители $\frac{g_1(t_n)g_2(t_n)}{r_1^0(t_n)r_2^0(t_n)}$ и $\varphi_n^D(\bar{\rho}_x, \bar{\rho}_z)$ не зависящими от n , что соответствует случаю наблюдения НК на сравнительно коротком участке траектории, когда можно пренебречь кривизной каналов дальности в окрестности цели и изменением значений нормированных ДН антенн РЛС в направлении на цель в процессе движения носителей РСА. При этом получим:

$$\varphi(\bar{\rho}_x, \bar{\rho}_z) = \left[\frac{g_1(t_n)g_2(t_n)}{r_1^0(t_n)r_2^0(t_n)} \right]^2 \varphi^D(\bar{\rho}_x, \bar{\rho}_z) \varphi^A(\bar{\rho}_x, \bar{\rho}_z), \quad (9.1.9)$$

где

$$\begin{aligned} \varphi^A(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-N}^N \exp \left\{ Jk_p \left[r_1 \left(\bar{\rho}_x, \frac{t_n}{\bar{x}^0}, \bar{x} \right) + \right. \right. \\ & \left. \left. + r_2 \left(\bar{\rho}_x, \frac{t_n}{\bar{x}^0}, \bar{x} \right) - r_1(\bar{\rho}_z, t_n) - r_2(\bar{\rho}_z, t_n) \right] \right\}. \end{aligned} \quad (9.1.10)$$

Рассмотрим свойства функции (9.1.10), входящей в выражение для функции неопределенности траекторного сигнала в виде независимого сомножителя.

$$\begin{aligned} \varphi_p^A(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-M_p}^{M_p} \exp \left\{ Jk_p \left[\alpha_{00}^p(\rho_x) - \beta_{00}^p(\rho_z) + \right. \right. \\ & \left. \left. + \sum_{i=1}^3 (\alpha_{i0}^p - \beta_{i0}^p + \bar{\alpha}_{i1}^p \bar{\rho}_x - \bar{\beta}_{i1}^p \bar{\rho}_z) (nT_p)^i \right] \right\}. \end{aligned} \quad (9.1.11)$$

В последнем выражении α соответствуют ожидаемому, а параметры β – реальному закону изменения дальности.

Анализ выражения (9.1.11) в первом приближении проведем с учетом следующих ограничений:

$$\alpha_{20}^p = \beta_{20}^p \quad \alpha_{30}^p = \beta_{30}^p \quad (9.1.12)$$

$$\bar{\alpha}_{21}^p = \bar{\beta}_{21}^p = 0 \quad \bar{\alpha}_{31}^p = \bar{\beta}_{31}^p = 0 \quad (9.1.13)$$

Использование допущений (9.1.12) и (9.1.13) позволяет рассматривать функцию (9.1.11), как сумму членов геометрической прогрессии. Эта сумма описывается следующим выражением:

$$\varphi^A(\bar{\rho}_x, \bar{\rho}_z) = \exp \left\{ Jk \left[\alpha_{00}(\bar{\rho}_x) - \beta_{00}(\bar{\rho}_z) \right] \right\} \times \\ \times \frac{\sin \left[k \left(\alpha_{10} - \beta_{10} + \bar{\alpha}_{11} \bar{\rho}_x - \bar{\beta}_{11} \bar{\rho}_z \right) \frac{T(2N+1)}{2} \right]}{\sin \left[k \left(\alpha_{10} - \beta_{10} + \bar{\alpha}_{11} \bar{\rho}_x - \bar{\beta}_{11} \bar{\rho}_z \right) \frac{T}{2} \right]}. \quad (9.1.14)$$

Предположим, что все параметры движения ПРЦ известны точно, то есть

$$\alpha_{10} = \beta_{10} \quad \bar{\alpha}_{10} = \bar{\beta}_{10} \quad (9.1.15)$$

Определим геометрическое место точек в пространстве координат изображения, для которых модуль (9.1.14) принимает наибольшее значение при отражении зондирующего сигнала от точки цели с координатой $\bar{\rho}_z$. Для этого необходимо решить относительно $\bar{\rho}_x$ уравнение

$$\bar{\alpha}_{11}(\bar{\rho}_x - \bar{\rho}_z) - 1 \frac{\lambda}{T} = 0; \quad 1 = 0, \pm 1, \pm 2, \dots \quad (9.1.16)$$

Это уравнение описывает в координатах изображения совокупность плоскостей, перпендикулярных вектору $\bar{\alpha}_{11}$. При $1 = 0$ имеем уравнение плоскости, проходящей через точку с координатами $\bar{\rho}_x = \bar{\rho}_z$ и удаленной от начала системы координат на расстояние

$$D(0) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z. \quad (9.1.17)$$

Расстояние от начала координат до 1-ой плоскости составляет

$$D_1(1) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z + 1 \frac{\lambda}{T_p |\bar{\alpha}_{11}|}, \quad (9.1.18)$$

а расстояние между соседними плоскостями –

$$D_2 = \frac{\lambda}{T_p |\bar{\alpha}_{11}|}. \quad (9.1.19)$$

Для нахождения нулей функции (9.1.14) следует решить уравнение

$$\bar{\alpha}_{11} (\bar{\rho}_x - \bar{\rho}_z) - m \frac{\lambda}{T(2M+1)} = 0; \quad m = \pm 1, \pm 2, \dots \quad (9.1.20)$$

Решение этого уравнения также описывает совокупность плоскостей в пространстве координат РЛИ, перпендикулярных вектору $\bar{\alpha}_{11}$. Эти плоскости следуют друг за другом чаще, чем плоскости, соответствующие максимумам (9.1.14). Удаление m -ой плоскости от начала координат составляет

$$d(M) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_x + m \frac{\lambda}{T(2M+1)|\bar{\alpha}_{11}|}. \quad (9.1.21)$$

При $m = \pm 1$ получаем два первых нуля рассматриваемой функции и определим обеспечиваемое ею разрешение

$$\Delta_\alpha^0 = D_0(1) - D_0(-1) = \frac{2\lambda}{T(2M+1)|\bar{\alpha}_{11}|}. \quad (9.1.22)$$

Таким образом, выражение (9.1.14) в пространстве изображений является функцией только одной координаты, измеряемой в направлении вектора $\bar{\alpha}_{11}$. Разрешающая способность в этом направлении определяется в соответствии с (9.1.22). Для однопозиционной РЛС при отсутствии собственного движения цели ($\bar{V}_{0p} = 0, \bar{\omega}_p = 0$) имеем:

$$\bar{\alpha}_{11} = - \frac{2\bar{V}_1}{|\bar{r}_{0p}(t_0) - \bar{r}_{0p}^p(t_0)|}. \quad (9.1.23)$$

Такая РЛС в направлении путевой скорости обеспечивает разрешение

$$\Delta = \frac{\lambda}{|\bar{V}_1| T(2M+1)} |\bar{r}_0(t_0) - \bar{r}_1^p(t_0)|. \quad (9.1.24)$$

В дальнейшем, в соответствии с терминологией, принятой при описании РЛС с синтезированной апертурой направление, задаваемое вектором $\bar{\alpha}_{11}$ будем именовать азимутальным. Примерный вид зависимости модуля (14) от азимутальной координаты показан на рис. 9.1.




Рис. 9.1. Азимутальное сечение модуля функции неопределённости

Используя (9.1.20) и (9.1.23) совместно с данными конкретной РЛС, например, типа SEASAT, нетрудно сделать вывод о том, что расстояние между пиками (9.1.14) во много раз превышает размеры существующих ПРЦ. Поэтому в дальнейшем ограничимся рассмотрением функции $\varphi^A(\rho_x, \rho_z)$ только в окрестности главного максимума, положение которого задается выражением (9.1.17).

При отсутствии точных данных о движении цели равенства (9.1.15) не соблюдаются. В этом случае положение максимума модуля функции (9.1.14) определяется уравнением

$$\bar{\alpha}_{11}\bar{\rho}_x - \bar{\beta}_{11}\bar{\rho}_z + \alpha_{10} - \beta_{10} = 0, \quad (9.1.25)$$

которое по-прежнему описывает плоскость, перпендикулярную вектору $\bar{\alpha}_{11}$. Однако, удаление ее от начала координат зависит не только от положения отражающей точки цели (вектор $\bar{\rho}_z$), но и от величины и ориентации вектора $\bar{\beta}_{11}$ и разности $(\alpha_{10} - \beta_{10})$:

$$D(0) = \frac{\bar{\beta}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z - \frac{\alpha_{10} - \beta_{10}}{|\bar{\alpha}_{11}|}. \quad (9.1.26)$$

При этом разрешение в азимутальном направлении по-прежнему задается выражением (9.1.22). Анализ (9.1.26) позволяет описать искажения РЛИ, которые возникают в тех случаях, когда априорные сведения о собственном движении цели не соответствуют действительности.

Предположим, что

$$\bar{\alpha}_{11} = \bar{\beta}_{11}; \quad \alpha_{10} = \beta_{10}. \quad (9.1.27)$$

Как следует из (9.1.26), все изображение цели сдвинется вдоль азимутальной оси на величину $(\beta_{10} - \alpha_{10})/|\bar{\alpha}_{11}|$. Допустим, что вектор $\bar{\beta}_{11}$ отличается от $\bar{\alpha}_{11}$ только постоянным множителем, то есть

$$\bar{\beta}_{11} = b\bar{\alpha}_{11}; \quad \alpha_{10} = \beta_{10}. \quad (9.1.28)$$

Из (9.1.26) следует, что азимутальная координата отклика от каждой точки на изображении изменится в « b » раз. Это приводит к сжатию ($b < 1$) или растяжению ($b > 1$) изображения цели по азимуту. Но такое изменение РЛИ не эквивалентно изменению масштаба по оси азимута, так как расстояние между первыми нулями функции φ^4 (14) не изменяется. В связи с этим для многоточечных целей при $b > 1$ возможно раздельное наблюдение откликов точек, не разрешаемых при $b = 1$. Наоборот, при $b < 1$ возможна потеря разрешения за счет наложения откликов соседних точек друг на друга.

Если вектора $\bar{\alpha}_{11}$ и $\bar{\beta}_{11}$ при равенстве модулей отличаются ориентацией в пространстве, то положение отклика от точки на изображении определяется ее проекцией на направление вектора $\bar{\beta}_{11}$. Поэтому взаимное расположение откликов от отражающих точек цели на азимутальной оси при изменении собственного движения ПРЦ сложным образом меняется.

Выражение (9.1.14) описывают функцию только одной координаты, измеряемой в направлении вектора $\bar{\alpha}_{11}$. Общеизвестно, что функция неопределенности одиночного импульсного сигнала $\varphi^4(\rho_x, \rho_z)$ обеспечивает разрешающую способность РЛС по наклонной дальности. Для би-статической РЛС направление, вдоль которого наблюдается наилучшее

разрешение по дальности, определяется геометрической суммой единичных векторов визирования цели приемной и передающей РЛС.

$$E = \frac{\bar{E}_1 + \bar{E}_2}{|\bar{E}_1 + \bar{E}_2|}. \quad (9.1.29)$$

Таким образом, функция неопределенности траекторного сигнала является функцией двух координат на плоскости, отсчитываемых вдоль направления наклонной дальности, заданного (9.1.29), и вдоль азимутального направления, единичный вектор которого равен $\bar{\alpha}_{11}/|\bar{\alpha}_{11}|$. Для удобства введем дополнительную систему координат $O' V_1 V_2 V_3$, центр которой совпадает с центром цели. Ось $O' V_1$ ориентирована по направлению вектора $\bar{\alpha}_{11}$. Ось $O' V_2$ совпадает с вектором визирования центра цели $\bar{E}_c$, а ось $O' V_3$ перпендикулярна двум другим осям и дополняет систему до правой декартовой. Отметим, что оси $O' V_1$ и $O' V_2$ в общем случае не ортогональны. При произвольном соотношении между модулями и направлениями векторов $\bar{\alpha}_{11}$ и $\bar{\beta}_{11}$ (9.1.26) можно представить в следующем виде:

$$D_1(0) = \frac{|\bar{\beta}_{11}|}{|\bar{\alpha}_{11}|} \left[\frac{|\bar{\beta}_{11}|}{|\bar{\beta}_{11}|} \bar{\rho}_z - \frac{\alpha_{10} - \beta_{10}}{|\bar{\beta}_{11}|} \right]. \quad (9.1.30)$$

Выражение в квадратных скобках определяет азимутальное положение максимума отклика от точки $\bar{\rho}_z$ цели на изображении для случая (9.1.27) с той лишь разницей, что в качестве азимутального используется направление вектора $\bar{\beta}_{11}$. Следовательно, изображение, получаемое в системе координат $O' V_1 V_2 V_3$, представляет собой масштабированное по азимутальной оси РЛИ, построенное в другой системе координат. Пространственная ориентация азимутальной оси этой системы координат в общем случае неизвестна.

На рис. 9.2 и 9.3 приведены примеры, иллюстрирующие рассмотренные искажения РЛИ. Предполагается, что цель состоит из трех отражающих точек, расположенных в одном канале дальности. На рис. 9а показано пространственное расположение точек цели в системе координат

$0' V_1 V_2 V_3$. На последующих рисунках показаны азимутальные сечения модулей функции неопределенности (9) для каждой из точек цели при различных соотношениях между $\bar{\alpha}_{11}$, $\bar{\beta}_{11}$, α_{10} и β_{10} .




Рис. 9.2. Примеры искажений РЛИ

Обратимся теперь к общему виду функции $\varphi^A(\rho_x, \rho_z)$ (9.1.11) и кратко рассмотрим, как отражается на свойствах РЛИ несоблюдение условий (9.1.13). Невыполнение (9.1.12), как следует из (9.1.11) приводит к расфокусировке откликов всех отражающих точек на изображении. Кроме того, происходит снижение максимума главного лепестка отклика. Нарушение неравенства (9.1.13) вызывает дополнительную расфокусировку. В наибольшей степени ей подвержены изображения точек, удаленных от центра цели.

Из сказанного выше следует, что к числу основных видов искажений РЛИ относятся:

- смещение изображений вдоль азимутальной оси,
- снижение разрешающей способности за счет расфокусировки,
- изменение взаимного расположения откликов от «блестящих точек» цели на изображении из-за несоблюдения равенства

$$\bar{\alpha}_{11} = \bar{\beta}_{11}. \quad (9.1.31)$$




Рис. 9.3. Примеры искажений РЛИ при различной ориентации векторов

$$(|\bar{\alpha}_{11}| = |\bar{\beta}_{11}|, \bar{\alpha}_{10} = \bar{\beta}_{10})$$

Первые два вида искажений достаточно хорошо известны [1, 2]. В ряде случаев удастся найти способы уменьшения их влияния [2, 3]. Значительно более сложной представляется ситуация снижения

третьего вида искажений. К нарушению условия (9.1.31) ведет незнание вектора собственной скорости цели относительно поверхности вектора угловой скорости вращения ПРЦ в момент ее наблюдения. Следовательно, собственное поступательное движение цели приводит к небольшим (порядка десятых долей процента) изменениям составляющих вектора $\bar{\beta}_{11}$. В то же время вращение ПРЦ может приводить к изменению компонент этого вектора в 10 и более раз. Таким образом, вращение цели является одним из самых существенных факторов, приводящих к искажению РЛИ.

В тех случаях, когда в модели отражающих НК присутствуют «мнимые блестящие точки», искажения РЛИ при наличии известной угловой скорости вращения имеют более сложный характер. Это связано с тем, что при вращении цели движение этих точек существенно отличается от движения самой цели. «Мнимые» точки образуют как бы отдельное жесткое тело, вектор угловой скорости которого в основной системе координат имеет вид:

$$\bar{\omega} = \{-\omega_1, -\omega_2, -\omega_3\},$$

тогда как для самой цели

$$\bar{\omega} = \{\omega_1, \omega_2, \omega_3\}.$$

В результате вектор $\bar{\beta}_{11}$ для «мнимых» точек может быть ориентирован в пространстве иначе, чем для остальной части цели. Итоговое изображение при этом представляет собой сумму двух РЛИ (самой цели и ее «мнимой» части), искаженных в равной степени.

В качестве иллюстрации проведенного анализа свойств РЛИ ниже рассмотрены изображения, полученные путем моделирования на ЭВМ без учета аддитивного шума радиолокационного тракта. При этом использовалась гипотетическая модель цели, состоящая из 11 «блестящих» точек без диффузионной составляющей. Координаты точек в системе координат, оси которой параллельны осям системы $0 X_1 X_2 X_3$, приведены в табл. 9.1, а их пространственное положение показано на рис. 9.4. Точки с 8-й по 11-ую являются «мнимыми», о чем, в частности, свидетельствуют отрицательные значения высот (координата X_3).

Таблица 9.1

Координаты точек ПРЦ

Номер точки	X_1 (м)	X_2 (м)	X_3 (м)
1	0	100	15
2	100	100	15
3	-50	0	30
4	0	0	0
5	50	0	30
6	-100	-100	15
7	0	-100	15
8	100	100	-15
9	50	0	-30
10	-100	-100	-15
11	0	-100	-15




Рис. 9.4. Гипотетическая модель цели

На рис. 9.5 приведена изометрическая проекция модуля комплексного РЛИ описанной цели при отсутствии собственного движения. Изображение занимает девять каналов дальности, сигналы в которых предполагаются статистически независимыми. Отклики всех точек пронумерованы. Высота пролета составляет 1000 км, горизонтальная дальность до цели 500 км. Как и следовало ожидать, азимутальное положение «мнимых точек» совпадает с положением порождающих их «блестящих точек».




Рис. 9.5. РЛИ цели без вращения

На рис. 9.6 показано изображение той же цели при наличии вращения вокруг оси OX_1 с угловой скоростью 10 мрад/с. При этом центральная точка цели своего положения не изменила. Остальные «блестящие точки» удалились от центра пропорционально своим истинным координатам. Смещение «мнимых точек» имеет противоположное направление. В результате этого структура изображения оказывается сильно искажена.




Рис. 9.6. РЛИ цели при вращении

9.2. Литература к главе 9

1. Радиолокационные станции обзора Земли / Г.С. Кондратенков, В.А. Потехин, А.П. Реутов, Ю.А. Феоктистов; под ред. Г.С. Кондратенкова. М.: Радио и связь, 1983. 271 с.

2. Curlander J.C. Wu C., Pang A. Automated preprocessing of spaceborne SAR data/ @Int. Geochi and remote Sens. Symp. (IGARSS'82) Munich, Juni 1-4, 1982, Dig Vol. 2". N.Y., 1982, FA1.3/1 FA 1/3/6&.

3. Wu K.H., Vant M.R. A SAR focusing technique for imaging targets with random motion. @Proc. IEEE Nat. Aerosp. and Electron.Conf. NAECON, Dayton, 21-25 May, 1984, vol. 1" York, N.Y., 1984 p. 289-295New.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	3
В.1. История дистанционного зондирования Земли из космоса [1]	4
В.2. Техника получения материалов дистанционного зондирования	5
В.3. РЛС с синтезированной апертурой.....	7
В.4. Литература к Введению.....	8
1. РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ (ОБЗОР СОВРЕМЕННОГО СОСТОЯНИЯ ПРОБЛЕМЫ)	9
1.1. Формирование вспомогательных дешифровочных признаков.....	10
1.1.1. Фурье-преобразование.....	10
1.1.2. Преобразование Радона.....	11
1.1.3. Преобразование Хафа.....	11
1.1.4. Вейвлет-преобразование	11
1.2. Методы снижения размерности	12
1.2.1. Метод главных компонент	13
1.2.2. Метод независимых компонент	13
1.2.3. Низкоранговое матричное разложение	14
1.3. Классификация без обучения	14
1.3.1. Пороговая обработка	15
1.3.2. Кластеризация	17
1.3.3. Нарращивание областей	18
1.3.4. Выделение границ	19
1.3.5. Модель активного контура	20
1.3.6. Скрытые марковские поля	22
1.3.7. Вывод по разделу 1.3	23
1.4. Классические методы	24
1.4.1. Байесовский классификатор	25
1.4.2. Дискриминантный анализ.....	27
1.4.3. Логистическая регрессия	28
1.4.4. Постоянная вероятность ложных тревог.....	28
1.4.5. Вывод по разделу 1.4.....	31
1.5. Классификация с обучением	31
1.5.1. Взаимная корреляционная функция.....	32
1.5.2. Расстояние Махаланобиса	33

1.5.3. Метод k -ближайших соседей	34
1.5.4. Метод опорных векторов	34
1.5.5. Метод разреженных представлений	36
1.5.6. Дерево решений	37
1.5.7. Модель <i>ASC</i>	38
1.5.8. Выводы по разделу 1.5	39
1.6. Глубокое обучение	39
1.6.1. Свёрточные нейронные сети	40
1.6.2. Автокодировщики	43
1.6.3. Ограниченная машина Больцмана	43
1.6.4. Глубокая сеть доверия	44
1.6.5. Рекуррентные нейронные сети	45
1.6.6. AdaBoost.....	46
1.6.7. Генетический алгоритм	47
1.6.8. Вывод по разделу 1.6.....	49
1.7. Вывод к главе 1.....	50
1.8. Литература к главе 1	51
2. РАДИОЛОКАЦИОННЫЕ СИСТЕМЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ	75
2.1. ALOS	75
2.2. COSMO-SkyMed.....	81
2.3. ERS	85
2.4. Envisat.....	90
2.5. RADARSAT.....	94
2.6. Sentinel.....	105
2.7. TerraSAR-X	109
2.8. TanDEM-X.....	111
2.9. PAZ.....	113
2.10. Основы распознавания пространственно-распределённых целей	115
2.11. Литература к главе 2	120
3. КЛАССИФИКАЦИЯ ПРЦ ПО ДАННЫМ КОСМИЧЕСКОЙ РЛС БОКОВОГО ОБЗОРА С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ	126
3.1. Математическая модель цели и отражённого сигнала при решении задач распознавания пространственно-распределённых целей в космических РЛС с синтезированной апертурой	126

3.2.	Многоальтернативная проверка гипотез относительно различных классов ПРЦ при их наблюдении совокупностью космических радиолокационных средств	134
3.3.	Адаптивный алгоритм классификации пространственно-распределённых целей по данным радиолокатора с синтезированной апертурой	140
3.4.	Алгоритмы автоматического группирования данных	151
3.4.1.	Чёткая и нечёткая декомпозиции	151
3.4.2.	Алгоритмы декомпозиции	156
3.5.	Литература к главе 3	161
4.	АНАЛИЗ АЛГОРИТМОВ КЛАССИФИКАЦИИ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ	162
4.1.	Границы Чернова и Кайлата – метод определения потенциальных возможностей классификации ПРЦ по вектору наблюдаемых данных	162
4.2.	Анализ потенциальных характеристик классификации ПРЦ по вектору наблюдаемых данных	170
4.3.	Методика расчета эффективности классификации ПРЦ по радиолокационному портрету	175
4.3.1.	Проблема анализа эффективности алгоритмов классификации	175
4.3.2.	Вывод расчетных выражений для оценки вероятностей правильных и ошибочных решений при классификации ПРЦ по РЛИ	180
4.3.3.	Оценка эффективности классификации при корнях большой кратности	192
4.4.	Анализ алгоритмов классификации по РЛИ ПРЦ	192
4.5.	Распознавание ПРЦ по данным разных средств наблюдения	193
4.5.1.	Коллективное распознавание	197
4.5.2.	Анализ эффективности классификации	199
4.6.	Методика расчета вероятности правильного распознавания при объединении решений отдельных СН методом простого голосования	203
4.7.	Литература к главе 4	205

5. ИЗМЕРЕНИЕ ПАРАМЕТРОВ РЛИ.....	206
5.1. Измерение общегрупповых параметров распределенной цели. Измерение координат центра РЛИ	206
5.1.1. Синтез оптимального измерителя общегруппового параметра групповой цели.....	206
5.1.2. Анализ эффективности алгоритма измерения координаты центра ПРЦ	212
5.2. Литература к главе 2	216
6. СИНТЕЗ ОПТИМАЛЬНЫХ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ПРЦ	217
6.1. Синтез оптимального алгоритма обнаружения ПРЦ при наличии в объеме разрешения не более одного элемента.....	217
6.2. Реализация и анализ оптимальных алгоритмов обнаружения и оценивания	228
6.3. Литература к главе 6	232
7. СИНТЕЗ И АНАЛИЗ КВАЗИОПТИМАЛЬНЫХ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ПРЦ.....	234
7.1. Квазиоптимальные алгоритмы с дискретным накоплением при большом числе уровней квантования	235
7.1.1. Неодинаковые P_i	235
7.1.2. Одинаковые P_i	240
7.2. Квазиоптимальные алгоритмы с дискретным накоплением при малом числе уровней квантования	245
7.2.1. Неодинаковые P_i	245
7.2.2. Одинаковые P_i	250
7.3. Квазиоптимальные алгоритмы с выбором максимума.....	263
7.3.1. Квазиоптимальный алгоритм с полным выбором максимума.....	263
7.3.2. Квазиоптимальный алгоритм с межпериодным накоплением и выбором максимума	269
7.4. Квазиоптимальные алгоритмы с использованием порядковых статистик.....	276
7.4.1. Одинаковые P_i	280
7.4.2. Неодинаковые P_i	285
7.5. Квазиоптимальные комбинированные алгоритмы	288

7.5.1. Комбинированный алгоритм с аналоговым накоплением и полным выбором максимума.....	288
7.5.2. Комбинированные алгоритмы с аналоговым накоплением и межпериодным выбором максимума	294
7.6. Литература к главе 7	297
8. ИССЛЕДОВАНИЕ АЛГОРИТМОВ ОЦЕНИВАНИЯ ОБЩЕГРУППОВЫХ ПАРАМЕТРОВ ПРЦ.....	299
8.1. Алгоритмы формирования цифровой модели радиолокационного изображения.....	300
8.1.1. Оптимальный алгоритм выделения сигнальных дискретов	300
8.1.2. Квазиоптимальный алгоритм выделения сигнальных элементов.....	301
8.2. Алгоритмы обработки цифровой модели радиолокационного изображения ПРЦ.....	305
8.2.1. Алгоритмы группирования	305
8.2.2. Алгоритм классификации и оценивания общегрупповых параметров	308
8.3. Анализ результатов статистического моделирования алгоритмов оценивания общегрупповых параметров ПРЦ.....	309
8.3.1. Сравнение оптимального и квазиоптимального алгоритмов выделения сигнальных дискретов	310
8.3.2. Характеристики оценивания при использовании квазиоптимального алгоритма выделения сигнальных дискретов и релеевской модели отраженного сигнала	312
8.3.3. Влияние когерентной составляющей в отраженном сигнале на характеристики оценивания	321
8.4. Литература к главе 8	325
9. ОСОБЕННОСТИ ПОЛУЧЕНИЯ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ДВИЖУЩИХСЯ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЕННЫХ ЦЕЛЕЙ.....	327
9.1. Искажение РЛИ при движении ПРЦ.....	327
9.2. Литература к главе 9	342

Научное издание

Доросинский Леонид Григорьевич
Виноградова Нина Сергеевна

**ОБРАБОТКА СИГНАЛОВ
ОТ ПРОСТРАНСТВЕННО
РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ**

Монография



Технический редактор Кулакова Г.А.

Подписано в печать 08.08.2023

Бумага офсетная.

Гарнитура NewtonС

Формат 60×84 1/16

Печать трафаретная. Печ. л. 21,75

Тираж 500 экз. Заказ № 14-23.

Отпечатано в типографии ИД «Академия Естествознания»,
440026, г. Пенза, ул. Лермонтова, 3