РАЗДЕЛ II. ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Акинин М.В., Балакин В.А., Братулин А.В., Кузнецов В.В.

Вопросы организации мультиклассового метода опорных векторов в задачах дешифрации данных дистанционного зондирования Земли

Рязанский государственный радиотехнический университет
(Россия, Рязань)

doi: 10.18411/sr-10-12-2017-02

idsp: 000001:sr-10-12-2017-02

Аннотация

В статье рассматриваются вопросы организации мультиклассового метода опорных векторов и его применения в задачах дешифрации данных дистанционного зондирования Земли (ДЗЗ). Отметим, что к источникам исходных данных ДЗЗ предъявляются достаточно высокие требования, о чем будет сказано ниже.

Ключевые слова: метод опорных векторов (Support Vector Machine, SVM), дистанционное зондирование Земли (ДЗЗ), классификация наборов данных, обучение по прецедентам.

Метод опорных векторов (Support Vector Machine, SVM) – это метод машинного обучения, целью которого является попытка классифицировать входные наборы данных. Классификация состоит в определении, к какому из, как минимум, двух изначально известных классов относится данный набор. Если классов несколько, имеет место многоклассовая (мультиклассовая) классификация. Также могут иметься образцы каждого класса – объекты, про которые заранее известно к какому классу они принадлежат. Для эффективной работы метода сначала необходимо использовать обучающую выборку, состоящую из входных и выходных данных, которая необходима для построения модели метода опорных векторов, и которую в дальнейшем можно будет использовать для классификации новых данных [1].

Если формулировать задачу дешифрации данных ДЗЗ предельно простым языком, можно сказать следующее: берется каждый пиксель спутникового снимка и делается попытка определить, к какому классу он относится – водный объект, лес, луг, и т. д.

До перехода к описанию мультиклассового метода опорных векторов сформулируем требования к источникам исходных данных ДЗЗ и к самим исходным данным ДЗЗ.

В качестве источников данных ДЗЗ можно рассматривать космические аппараты (КА), соответствующие следующим критериям:

- достаточная информативность;
- частота обновления данных;
- способ распространения данных;
- запуск КА в промежутке с 2012 по 2014 годы и невыработка КА расчетного срока службы;
- доступность спутниковых снимков российскому потребителю.

Под достаточной информативностью спутниковых снимков понимается соответствие снимков следующим критериям:

- достаточное разрешение (30-60 метров на 1 пиксель);
- достаточное количество спектральных каналов (телевизионное, ТВ-изображение: спектральные каналы R, G и B; и тепловизионное, ТПВ-изображение: спектральные каналы R и NIR).

Также к исходным данным ДЗЗ предъявляются следующие обязательные требования:

- распространение данных с привязкой к системе координат WGS-84 в проекции UTM;
- наличие радиометрической и геометрической коррекции.

Для глубокого и полного понимания мультиклассового метода опорных векторов необходимо напомнить основные обозначения метода.

Рассматривается задача обучения по прецедентам $\langle X, Y, y^*, X\ell \rangle$, где X – пространство объектов; Y – множество ответов; $y^*: X \rightarrow Y$ – целевая зависимость, значения которой известны только на объектах обучающей выборки $X\ell = (x_i, y_i)_{i=1}^l$, $y_i = y^*(x_i)$. Требуется построить алгоритм $a: X \rightarrow Y$, аппроксимирующий целевую зависимость на всём пространстве X .

Рассмотрим задачу классификации на два непересекающихся класса, в которой объекты описываются n -мерными вещественными векторами:

$$X = R^n, Y = \{-1, +1\}$$

Будем строить линейный пороговый классификатор:

$$a(x) = \text{sign} \left(\sum_{j=1}^n w_j x^j - w_0 \right) = \text{sign}(\langle w, x \rangle - w_0),$$

где $x = (x_1, \dots, x_n)$ – признаковое описание объекта x ; вектор $w = (w_1, \dots, w_n) \in R^n$ и скалярный порог $w_0 \in R$ являются параметрами алгоритма.

Уравнение $\langle w, x \rangle = w_0$ описывает гиперплоскость, разделяющую классы в пространстве R^n .

Хотя правило классификации в точности совпадает с моделью нейрона по МакКаллоку-Питтсу, критерий и методы настройки параметров в SVM радикально отличаются от персептронных (градиентных) методов обучения.

В случае нескольких классов (мультиклассовый метод) на практике зачастую применяется решающее правило, основанное на разбиении задачи на бинарные по схеме «один против остальных» (One-vs-Rest):

$$f(x) = \arg \max_{y \in Y} (\langle w_y, x \rangle + b_y).$$

Здесь b_y – некоторое число.

Стоит отметить, что дальнейшее обобщение такого решающего правила приводит к методу опорных векторов со структурированным результатом (Structured Output SVM).

Для обучения параметров $w_0, b_0, \dots, w_N, b_N$ такой композиции алгоритмов может быть решено N стандартных для метода опорных векторов задач оптимизации, однако данный подход имеет свои недостатки.

В работе Краммера и Зингера была предложена следующая совместная формулировка задачи оптимизации

$$\min_{w, \xi} \frac{1}{2} \|w_y\|^2 + C \sum_i \xi_i,$$

при ограничениях $\langle w_y, x_i \rangle - \langle w_y, x_i \rangle \geq 1 - \delta_{y_i, y} - \xi_i$, $\xi_i \geq 0$ задающих ответы классификатора на обучающей выборке и ограничениях положительности штрафов.

Двойственная задача такой формулировки имеет вид

$$\min_{\alpha} \frac{1}{2} \sum_{y \in Y} \sum_i \sum_j \alpha_i^y \alpha_j^y \langle x_i, x_j \rangle + \sum_{y \in Y} \sum_i (1 - \delta_{y_i, y}) \alpha_i^y$$

при неотрицательных коэффициентах

Преимущества мультиклассового метода опорных векторов:

- автоматически определяется число нейронов скрытого слоя. Оно равно числу опорных векторов.
- принцип оптимальной разделяющей гиперплоскости приводит к максимизации ширины разделяющей полосы между классами, следовательно, к более уверенной классификации. Градиентные нейросетевые методы выбирают положение разделяющей гиперплоскости произвольным образом.
- Недостатки мультиклассового метода опорных векторов:
- метод опорных векторов неустойчив по отношению к шуму в исходных данных. Если обучающая выборка содержит шумовые выбросы, они будут существенным образом учтены при построении разделяющей гиперплоскости. Этого недостатка лишён метод релевантных векторов (relevance vector machine, RVM). В отличие от SVM данный метод дает вероятности, с которыми объект принадлежит данному классу. Т.е. если SVM говорит «x принадлежит классу А», то RVM скажет «x принадлежит классу А с вероятностью p и классу В с вероятностью 1-p».
- в общем случае, когда линейная делимость не гарантируется, приходится подбирать управляющий параметр алгоритма [2].

1. Акинин М.В., Конкин Ю.В. Особенности обучения машины опорных векторов в задачах формирования карт лесов // Методы и средства обработки и хранения информации. 2010, – С. 130-140.
2. Bartlett P., Shawe-Taylor J. Generalization performance of support vector machines and other pattern classifiers // Advances in Kernel Methods. – MIT Press, Cambridge, USA, 1998.

Воробьев А.И.¹, Колбанёв М.О.²

Инфокоммуникация и архитектура цифровой экономики

¹Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

²Санкт-Петербургский государственный экономический университет
(Россия, Санкт-Петербург)

doi: 10.18411/sr-10-12-2017-03

idsp: 000001:sr-10-12-2017-03

Аннотация

В статье рассмотрены особенности архитектурных подходов к созданию централизованных и децентрализованных цифровых платформ на базе инфокоммуникационных сетей и систем. Многоцелевая модель перехода к цифровой экономике, цифровые платформы и экосистема цифровой экономики. Рассмотрены децентрализованные цифровые платформы блокчейн и связанные с ним понятия, программируемая экономика, иерархия технологий, примеры приложений.

Ключевые слова: инфокоммуникация, цифровая экономика, программируемая экономика, цифровая платформа, блокчейн, майнинг.

Для создания цифровой экономики нужно достигнуть 3-х взаимосвязанных целей[1]. На глобальном уровне должен быть создан единый цифровой рынок