Сегментация мультиспектральных снимков с применением свёрточных нейронных сетей

Е. С. Иванов, И. П. Тищенко, А. Н. Виноградов

*Институт программных систем им. А. К. Айламазяна РАН
Переславль-Залесский, 152020, Россия
E-mail: egor.s.ivanov@gmail.com*

Работа посвящена обработке аэрокосмических мультиспектральных снимков, полученных при дистанционном зондировании Земли, а именно сегментации. Целью статьи является описание метода сегментации мультиспектральных снимков с использованием свёрточных нейронных сетей. В компьютерной графике сегментация — сложная задача, на результаты работы которой может влиять множество факторов: шум на изображении, текстура и т. д. Изображения, полученные в результате сегментации, могут быть использованы для последующего анализа с менее затратными ресурсами. В статье описано общее понятие о нейронных сетях свёрточного типа, описана их архитектура. С использованием свёрточных нейронных сетей был разработан и реализован подход к сегментации мультиспектральных снимков, который также представлен в данной статье. Предложенные методы обработки снимков позволяют избежать исчезновения объектов, их ложного появления (избыточная сегментация) и неточности определения их границ на результатах сегментации. В качестве исходных данных использовались снимки, полученные со спутника Terra при помощи инструмента ASTER. Приведены результаты сегментации мультиспектральных снимков дистанционного зондирования Земли. Обосновано преимущество использования оригинальных мультиспектральных снимков по сравнению с трёхканальными (RGB) изображениями.

Ключевые слова: сегментация изображений, дистанционное зондирование, компьютерное зрение, обработка изображений, мультиспектральные снимки, свёрточные нейронные сети

Одобрена к печати: 25.12.2018

DOI: 10.21046/2070-7401-2019-16-1-25-34

Введение

Материалы космической съёмки в нескольких зонах энергетического спектра, преимущественно в видимом (0,4–0,7 мкм) и ближнем инфракрасном (0,7–1,3 мкм) диапазонах, представляют большой интерес для решения многих задач. Спектральные отражательные свойства растительности и почвеннорастительных комплексов зависят от состава, структуры, фазы вегетации, климатических и многих других факторов (Чабан и др., 2009). Поэтому в настоящее время всё больше и больше возрастает интерес к обработке данных, полученных со спутников дистанционного зондирования Земли (ДЗЗ). Эти данные могут использоваться для решения самых различных задач, таких как мониторинг состояния почвы, водоёмов и растительности; выявление очагов лесных пожаров; мониторинг и оценка эффективности лесовосстановительной деятельности; контроль природопользования (вырубки леса, строительства карьеров, незаконных свалок, оценка рациональности при добыче природных ресурсов и пр.); создание геокарт; инвентаризация объектов на охраняемых территориях; мониторинг строительных объектов и т. д.

Применение различных методов предварительной обработки снимков позволяет сократить время, затраченное на решение задачи, а в некоторых случаях полностью автоматизируют этот процесс. Например, инвентаризацию можно свести к задаче поиска и распознавания объектов на снимках. Контроль вырубки лесов — к задаче сравнения площадей лесных массивов на разновременных снимках одного и того же участка, для решения которой нужно автоматическое выделение лесов на снимках, что можно сделать с помощью методов сегментации.

Сегментация является одним из важнейших этапов анализа цифрового изображения (Пестунов, Рылов, 2012). Она заключается в разбиении изображения на области, которые являются однородными по некоторым признакам (это может быть схожесть спектральных данных, схожесть текстуры, формы и др.). Предполагается, что получаемые области соответствуют реальным объектам или их частям (Барталев, Ховратович, 2011).

Сегментированное изображение даёт более удобную возможность последующей обработки. В том числе это связано с тем, что на изображении уже отсутствует резкий перепад яркости пикселей и однородные области представляют единое целое. В результате сегментации последующий анализ изображения происходит не на уровне пикселей, а на уровне выделенных суперпикселей, т. е. объектов.

Нейронные сети

Использование нейронных сетей в обработке данных обусловлено их схожестью с успешной работой биологических систем, которые, по сравнению с другими системами, состоят из простых и многочисленных нейронов, работающих параллельно и имеющих возможность обучения (Kriesel, 2007; Schmidhuber, 2015). Важной чертой нейронных сетей является то, что в силу конструктивных особенностей они позволяют успешно решать задачи с большим количеством переменных, не требуя большого количества вычислительных ресурсов (Хлопков, 2015).

Для сегментации снимков ДЗЗ была выбрана свёрточная нейронная сеть — специальная архитектура искусственных нейронных сетей, предложенная Яном Лекуном и нацеленная на эффективное распознавание изображений. Свёрточная нейронная сеть состоит из нескольких слоёв. Они могут быть трёх типов: свёрточные, слои выборки и полносвязные.

Первым всегда выступает свёрточный слой, где фильтром является матрица. Этот фильтр обходит всё изображение скользящим окном с шагом в 1 пиксель. На каждом шаге он накладывается на изображение и производит операцию свёртки, т. е. поэлементно умножаются значения фильтра на соответствующие значения яркости пикселя. Эти величины суммируются, и в итоге получается одно число, передающееся в новое изображение, которое имеет размер меньше исходного (Романов, 2018). На *рис. 1* показан пример операции свёртки изображения при помощи фильтра размером 5×5 .

Рис. 1. Пример операции свёртки изображения с помощью фильтра размером 5×5

Следующий тип — это слои выборки. Слой выборки берёт небольшие прямоугольные блоки из свёрточного слоя и обрабатывает их для создания одного выхода из взятого блока. Слой данного типа может выдавать среднее значение, максимум или использовать линейную комбинацию значений в блоке. Свёрточные слои и слои выборки строят карту признаков. Каждая карта признаков в идеале фильтрует изображение, находя какой-то один определённый, специфичный для данной карты, признак (Дорогой, 2012).

Последний тип — полносвязные слои. Полносвязный слой принимает карту признаков из предыдущего слоя и строит N -мерный вектор (где N — число классов). Работа организуется путём обращения к выходу предыдущего слоя и определения свойств, которые наиболее характерны для конкретного класса. После полносвязных слоёв не может быть слоёв свёртки (Sarangi, Sekhar, 2015).

Комбинируя размеры входных изображений, последовательность и количество слоёв, можно получить различные архитектуры нейронных сетей.

Для проведения экспериментов был использован размер входного изображения 32×32 пикселя. Этот размер является достаточным для того, чтобы в процессе обучения и распознавания использовать текстурные особенности фрагментов снимков: они попадают на фрагменты, но при этом не занимают большую часть. Была применена одна из наиболее распространённых архитектур нейронной сети, поочерёдно состоящая из слоёв свёртки и выборки (по шесть слоёв каждого типа) и с завершающим полносвязным слоем. Размер фильтра свёртки на первом слое составил 3×3 , а на последующих — 2×2 , размер окна выборки — 2×2 . Общее количество слоёв в нейронной сети было равно 13. Выбранная архитектура показана на рис. 2.

Рис. 2. Выбранная архитектура свёрточной нейронной сети

Подготовка данных для обучения нейронной сети

Для обучения нейронной сети необходимо подготовить обучающую выборку. Создание обучающей выборки — важный шаг, поскольку от него зависит, как обучится сеть и как это повлияет на конечный результат распознавания.

Создание выборки производилось с использованием множества исходных снимков, полученных со спутника Terra при помощи инструмента ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer, NASA, <https://search.earthdata.nasa.gov/search>). Каналы таких мультиспектральных снимков имеют разное разрешение. В данном случае в зависимости от содержащегося в канале спектра разрешение канала принимало одно из следующих значений: 4200×4980 , 2100×2490 , 700×830 . Для того чтобы обрабатывать снимки целиком, а не каналы по отдельности, сначала все каналы были приведены к единому размеру 4200×4980 при помощи операции масштабирования.

Следующий шаг — задание регионов на снимках, содержащих те или иные области, для последующего их преобразования в фрагменты, подаваемые нейронной сети для обучения.

При создании обучающей выборки были выбраны шесть различных классов поверхности, для каждого из которых определён свой цвет закраски:

- 1) граничные области — тёмно-серый;
- 2) растительность (леса, трава) — зелёный;
- 3) река и околоречная поверхность — фиолетовый;
- 4) водная поверхность — синий;
- 5) облака над землёй — светло-серый;
- 6) облака над водой — коричневый.

На *рис. 3* приведены примеры задания областей, содержащих фрагменты для обучения. Регионы определялись пользователем при помощи координат противоположных углов прямоугольника (левый верхний и правый нижний) и номера класса, к которому относится выделяемая область.

Рис. 3. Задание областей на снимках. Серым цветом выделена граничная область, зелёным — растительности, жёлтым — облака над землёй, синим — водная поверхность

В ходе работ написана программа, выполняющая нарезку мультиспектрального снимка на фрагменты нужного размера (производилась нарезка на фрагменты величиной 32×32) с заранее заданных участков снимка. Обучающая выборка содержала шесть классов, общее число объектов составило более 2000 мультиспектральных изображений, по 15 каналов в каждом, каждый канал представляет матрицу размером 32×32 . В качестве формата хранения обучающей выборки использовался hdf (The HDF Group, <https://www.hdfgroup.org/>).

Следующий шаг — обучение нейронной сети. На вход подавалась обучающая выборка. Данные из неё выбирались случайным образом. Ошибкой обучения нейронной сети является отношение неверно классифицированных изображений из некоторого случайного множества к общему числу изображений в этом множестве. Ошибка обучения составила 2,42 %.

Сегментация

В силу того, что каналы исходного мультиспектрального снимка имеют разный размер, перед выполнением сегментации необходимо, так же как и в случае создания обучающей выборки, выполнить масштабирование слоёв с целью приведения их к единому размеру.

Как правило, сегментация при помощи нейронных сетей происходит следующим образом: снимок обходится маской и разбивается на равные фрагменты, каждый из которых подаётся нейронной сети на распознавание (Ronneberger et al., 2015); нейронная сеть для каждого фрагмента вычисляет класс и вероятность, с которой он относится к этому классу. В статье (Li et al., 2017) авторы разбивают снимок на фрагменты размером 5×5 . В зависимости от результата распознавания участок сегментированного изображения окрашивается в цвет, соответствующий классу этого фрагмента. Недостатком подобного подхода стал факт, что фрагменты, на которые разбивается исходный снимок, не пересекаются.

Рассмотрим пример, показанный на *рис. 4* (см. с. 29). Предположим, что в центре снимка расположен водоём, а остальную часть занимает растительность. При разбиении изображения на четыре равных непересекающихся фрагмента водоём попадает в каждый из них.

Однако размер водоёма в этих участках очень мал, поэтому каждый из четырёх фрагментов такого разбиения будет принадлежать классу растительности и на итоговом сегментированном изображении водоём просто исчезнет. Частично эта проблема решается при помощи уменьшения размера разбиваемых фрагментов: их количество возрастёт, поэтому найдутся фрагменты, где водоём будет занимать большую часть. Однако с уменьшением размеров появляется другая проблема: шум и текстура на снимках приводят к нежелательной и избыточной сегментации.

В связи с этим возникает необходимость разбиения на пересекающиеся фрагменты. Это было учтено в работе (Соловьев и др., 2017). Авторы обрабатывали снимки методом сканирующего окна с таким шагом, чтобы области перекрывались на 50 % (в дополнительных экспериментах они увеличивали это значение до 75 % и более), используя при этом фиксированный размер скользящего окна, что не всегда даёт хороший результат по причине, описанной выше. В статье (Ciresan et al., 2012) авторы используют скользящее окно с шагом в 1 пиксель, тем самым происходит классификация каждого конкретного пикселя на основании смежных с ним пикселей.

Однако часто возникает ситуация, когда нейронная сеть относит фрагмент к некоторому классу с низкой вероятностью. Поэтому при принятии решения о классификации рассматриваемой области также следует учитывать эту вероятность: если она ниже допустимого порога, то не следует классифицировать заданный участок на данном шаге. Таким образом, исключается появление некоторых ложных объектов на итоговом изображении, но вместе с этим возникает вероятность, что некоторые фрагменты вовсе не будут классифицированы. Для решения этой задачи используется обход снимка масками разных размеров. Изначально проводится классификация всего снимка. Затем — обходы снимка разными масками, при каждой последующей итерации размер маски уменьшается. Участок обрабатываемого снимка под маской масштабируется до размера 32×32 и передаётся нейронной сети для классификации. Если вероятность отнесения фрагмента к полученному классу больше некоторого порогового значения, то считается, что он принадлежит этому классу. В зависимости от полученного класса соответствующий фрагмент нового (сегментированного) изображения окрашивается в определённый цвет, либо (в случае, когда найденная вероятность меньше порогового значения) окрашивание на данном шаге не происходит. Таким образом, при уменьшении размера маски постепенно происходит повышение детализации сегментации. Данный процесс изображён на *рис. 5* (см. с. 30). Вверху слева представлен канал исходного снимка, затем показана оценка всего изображения: так как большую часть на снимке занимает вода, то оно окрашено в соответствующий цвет. Следующим изображением показана улучшенная детализация сегментов (размер скользящего окна 800×800 пикселей), затем границы сегментов становятся более плавными и за счёт уменьшения размера маски появляются новые детали. Процесс сегментации завершается, как только выполнен обход снимка скользящим окном с наименьшим из заданных размеров (в данном случае — 32×32).

Таким образом, если при использовании маски небольшого размера не был вычислен класс для некоторого участка снимка, то он для данного участка остаётся таким же, каким был определён ранее. В настоящий момент авторам статьи не известны работы, в которых используется подобный принцип — обход скользящим окном разных размеров с учётом вероятности.

Результаты сегментации снимков ДЗЗ в проведённых экспериментах представлены на *рис. 6–8* (см. с. 30–31).

Рис. 4. Пример плохого разбиения на равные непересекающиеся фрагменты

Рис. 5. Пример повышения детализации сегментации при уменьшении размера скользящего окна (слева направо, сверху вниз)

Рис. 6. Канал исходного снимка (слева) и результат сегментации при помощи нейронной сети (справа)

Рис. 7. Канал исходного снимка (слева) и результат сегментации при помощи нейронной сети (справа)

Рис. 8. Фрагмент канала исходного снимка (слева) и соответствующий фрагмент результата сегментации при помощи нейронной сети (справа)

Рис. 9. Фрагмент участка исходного снимка (слева) и соответствующий фрагмент сегментированного изображения, на котором коричневым цветом выделены облака над водой и серым цветом — облака над сушей (справа)

Показано, что подобный подход к сегментации мультиспектральных снимков позволяет различить облака, расположенные как над водой, так и над землёй (рис. 9). На каналах, которые в естественных условиях видны человеческому глазу (RGB-изображения), их текстура отличается незначительно, но на каналах снимков, снятых в недоступных человеческому глазу спектрах (ближний инфракрасный, дальний инфракрасный и пр.), они содержат гораздо больше различий.

При использовании спектров, невидимых человеческому глазу, можно провести анализ влажности почвы, узнать состав горных пород, состояние атмосферы, отражение состояния растительности, состояние водоёмов, заражение сельскохозяйственных посевов вредителями и пр. (MapExpert, URL: http://mapexpert.com.ua/index_ru.php?id=12&table=news). Например, в силу особенностей отражения света хлорофиллом с поверхности растений в красном и ближнем инфракрасном диапазонах эти каналы широко используются при анализе растительного покрова. Мультиспектральные снимки позволяют произвести сегментацию на различные горные породы, здоровые и больные растения, влажные и сухие участки почвы и т. д., что практически невозможно для снимков, снятых в видимом диапазоне.

Выводы

Реализован метод сегментации мультиспектральных снимков ДЗЗ. Несмотря на то, что существует множество методов и алгоритмов сегментации трёхканальных снимков, решение этой задачи для мультиспектральных изображений играет важную роль в области обработки космических данных, поскольку даёт более точные результаты. Преимущество использования мультиспектральных снимков заключается в том, что на них присутствуют каналы (спектры), содержащие диапазон, невидимый человеческому глазу. Достоинство использования нейронных сетей в процессе сегментации снимков ДЗЗ заключается в том, что пиксель на снимке классифицируется (относится к тому или иному классу) с учётом целой области пикселей; таким образом, снижается негативное влияние шумов на снимках, а также повышается устойчивость к текстурным изменениям. За счёт перекрытия областей в процессе обхода снимка, использования порогового значения вероятности и обхода масками разных размеров предложенный метод сегментации снимков ДЗЗ позволяет избежать исчезновения объектов, их ложного появления (избыточная сегментация) и неточности определения их границ на результатах сегментации.

Работа выполнялась при финансовой поддержке Минобрнауки России в рамках проекта RFMEFI60716X0153.

Литература

1. *Барталев С. А., Ховратович Т. С.* Анализ возможностей применения методов сегментации спутниковых изображений для выявления изменений в лесах // Современные проблемы дистанционного зондирования Земли из космоса. 2011. Т. 8. № 1. С. 44–62. URL: http://d33.infospace.ru/d33_conf/2011v8n1/044-062.pdf.
2. *Дорогой Я. Ю.* Архитектура обобщенных сверточных нейронных сетей // Вестник НТУУ КПИИ. 2011. № 54. С. 229–234. URL: http://www.it-visnyk.kpi.ua/wp-content/uploads/2012/08/54_36.pdf.
3. *Пестунов И. А., Рылов С. А.* Алгоритмы спектрально-текстурной сегментации спутниковых изображений высокого пространственного разрешения // Вестник Кемеровского гос. ун-та. 2012. № 4(52). Т. 2. С. 104–109.
4. *Романов А. А.* Сверточные нейронные сети // 21-я Международная научно-практич. конф. «Научные исследования: ключевые проблемы III тысячелетия»: сб. тр. конф. 2018. С. 5–9. URL: <https://scientificresearch.ru/images/PDF/2018/21/svertochnye.pdf>.
5. *Соловьев Р. А., Тельпухов Д. В., Кустов А. Г.* Автоматическая сегментация спутниковых снимков на базе модифицированной свёрточной нейронной сети UNET // Инженерный вестник Дона. 2017. Т. 47. № 4(47). URL: http://ivdon.ru/uploads/article/pdf/IVD_56_soloviev_N.pdf_116222c2f5.pdf.
6. *Хлопков Ю. И.* Применение искусственных нейронных сетей в гиперзвуковой аэродинамике // Международный журн. прикладных и фундаментальных исследований. 2015. № 4-1. С. 45–49.
7. *Чабан Л. Н., Вечерук Г. В., Гаврилова Т. С.* Исследование возможностей классификации растительного покрова по гиперспектральным изображениям в пакетах тематической обработки данных дистанционного зондирования // Труды Московского физико-технич. ин-та. 2009. Т. 1. № 3. С. 171–180. URL: https://mipt.ru/za-nauku/upload/7ce/f_eduu-arphcx11tgs.pdf.
8. *Ciresan D., Giusti A., Gambardella L., Schmidhuber J.* Deep neural networks segment neuronal membranes in electron microscopy images // Advances in Neural Information Processing Systems. 2012. P. 2843–2851. URL: <http://people.idsia.ch/~juergen/nips2012.pdf>.
9. *Kriesel D.* A Brief introduction to Neural Networks. Version ZETA2-EN. 2007. 226 p. URL: http://www.dkriesel.com/_media/science/neuronale-netze-en-zeta2-2col-dkrieselcom.pdf.
10. *Li Y., Zhang H., Shen Q.* Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network // Remote Sensing. 2017. V. 9. No. 1. P. 67.
11. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // Intern. Conf. Medical Image Computing and Computer-Assisted Intervention. 2015. P. 234–241.
12. *Sarangi N., Sekhar C.* Tensor Deep Stacking Networks and Kernel Deep Convex Networks // 4th Intern. Conf. Pattern Recognition: Applications and Methods (ICPRAM). 2015. P. 267–281.
13. *Schmidhuber J.* Deep learning in neural networks: An overview // Neural Networks. 2015. V. 61. P. 85–117.

Multispectral image segmentation using convolutional neural network

E. S. Ivanov, I. P. Tishchenko, A. N. Vinogradov

Program Systems Institute RAS, Pereslavl-Zalessky 152020, Russia

E-mail: egor.s.ivanov@gmail.com

The paper is devoted to a processing of remote sensing aerospace multispectral images, namely, segmentation. In computer vision, image segmentation is a difficult task. The results of segmentation can be influenced by many factors: the noise of the image, texture, etc. Images obtained from the Terra satellite, with the use of the ASTER tool, were used as the initial data set for the operation of the neural network. The method of image processing, proposed in the article, makes it possible to avoid the disappearance of objects, their false appearance (redundant segmentation), and inaccuracies in determining the boundaries of the results of segmentation. Furthermore, the paper describes the methods of preliminary processing, data preparation, and the advantage of using multichannel images as compared to RGB image segmentation. Examples of segmentation of multispectral remote sensing images are given and the advantages of using neural networks in place of common segmentation algorithms are described. Lastly, the results of image segmentation can be used for subsequent analysis with less expensive resources.

Keywords: image segmentation, remote sensing, computer vision, image processing, multispectral images, convolutional neural networks

Accepted: 25.12.2018

DOI: 10.21046/2070-7401-2019-16-1-25-34

References

1. Bartalev S. A., Khovratovich T. S., Analiz vozmozhnostei primeneniya metodov segmentatsii sputnikovykh izobrazhenii dlya vyyavleniya izmenenii v lesakh (Analysis of the possibilities of applying satellite image segmentation techniques to detect changes in forests), *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2011, Vol. 8, No. 1, pp. 44–62, URL: http://d33.infospace.ru/d33_conf/2011v8n1/044-062.pdf.
2. Dorogoi Ya. Yu., Arkhitektura obobshchennykh svtochnykh neironnykh setei (The architecture of generalized convolutional neural networks), *Vestnik NTUU KPII*, 2011, No. 54, pp. 229–234, URL: http://www.it-visnyk.kpi.ua/wp-content/uploads/2012/08/54_36.pdf.
3. Pestunov I. A., Rylov S. A., Algoritmy spektral'no-teksturnoi segmentatsii sputnikovykh izobrazhenii vysokogo prostranstvennogo razresheniya (Spectral-textural segmentation algorithms for satellite images with high spatial resolution), *Vestnik Kemerovskogo gosudarstvennogo universiteta*, 2012, No. 4(52), Vol. 2, pp. 104–109.
4. Romanov A. A., Svtochnyye neironnyye seti (Convolutional neural networks), *1-ya Mezhdunarodnaya nauchno-prakticheskaya konferentsiya "Nauchnye issledovaniya: klyuchevyye problemy III tysyacheletiya"* (1st Intern. Science-Practical Conf. "Scientific Research: Key Problems of the III Millennium"), Proc., 2018, pp. 5–9, URL: <https://scientificresearch.ru/images/PDF/2018/21/svtochnyye.pdf>.
5. Solov'ev R. A., Telpukhov D. V., Kustov A. G., Avtomaticheskaya segmentatsiya sputnikovykh snimkov na baze modifitsirovannoi svtochnoi neironnoi seti UNET (Automatic segmentation of satellite images based on the modified UNET convolutional neural network), *Inzhenernyi vestnik Dona*, 2017, Vol. 47, No. 4(47), URL: http://ivdon.ru/uploads/article/pdf/IVD_56_soloviev_N.pdf_116222c2f5.pdf.
6. Khlopkov Yu. I., Primenenie iskusstvennykh neironnykh setei v giperzvukovoi aerodinamike (Application of artificial neural networks in hypersonic aerodynamics), *Mezhdunarodnyi zhurnal prikladnykh i fundamental'nykh issledovaniy*, 2015, No. 4-1, pp. 45–49.
7. Chaban L. N., Vecheruk G. V., Gavrilova T. S., Issledovanie vozmozhnostei klassifikatsii rastitel'nogo pokrova po giperspektral'nym izobrazheniyam v paketakh tematicheskoi obrabotki dannykh distantsionnogo zondirovaniya (Investigation of the possibilities of vegetation cover classification by hyperspectral images in packages of thematic processing of remote sensing data), *Trudy Moskovskogo fiziko-tekhnicheskogo instituta*, 2009, Vol. 1, No. 3, pp. 171–180, URL: https://mipt.ru/za-nauku/upload/7ce/f_eduu-arphcx1tgs.pdf.

8. Ciresan D., Giusti A., Gambardella L., Schmidhuber J., Deep neural networks segment neuronal membranes in electron microscopy images, *Advances in Neural Information Processing Systems*, 2012, pp. 2843–2851, URL: <http://people.idsia.ch/~juergen/nips2012.pdf>.
9. Kriesel D., *A Brief introduction to Neural Networks*, Version ZETA2-EN, 2007, 226 p., URL: http://www.dkriesel.com/_media/science/neuronale-netze-en-zeta2-2col-dkrieselcom.pdf.
10. Li Y., Zhang H., Shen Q., Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network, *Remote Sensing*, 2017, Vol. 9, No. 1, p. 67.
11. Ronneberger O., Fischer P., Brox T., U-net: Convolutional networks for biomedical image segmentation, *Intern. Conf. Medical Image Computing and Computer-Assisted Intervention*, 2015, pp. 234–241.
12. Sarangi N., Sekhar C., Tensor Deep Stacking Networks and Kernel Deep Convex Networks, *4th Intern. Conf. Pattern Recognition: Applications and Methods (ICPRAM)*, 2015, pp. 267–281.
13. Schmidhuber J., Deep learning in neural networks: An overview, *Neural Networks*, 2015, Vol. 61, pp. 85–117.