

Колесников А.А.¹, Кикин П.М.², Комиссарова Е.В.³, Касьянова Е.Л.⁴

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ ПРИ РЕШЕНИИ ГЕОИНФОРМАЦИОННЫХ ЗАДАЧ

АННОТАЦИЯ

Машинное обучение и анализ данных являются наиболее популярными направлениями как в информационных технологиях, так и среди большинства направлений научных исследований. География, картография и геоинформатика с их разнообразием типов исходных и обрабатываемых данных, задач пространственного анализа, способов визуализации, способов моделирования и прогнозирования как нельзя лучше подходят для использования современных алгоритмов машинного обучения. Однако использование этих технологий редко выходит за рамки решения частных задач коммерческих компаний и зачастую не находит широкой огласки и тем более какой-либо систематизации и научного описания. В связи с этим было решено провести исследование технологий машинного обучения на предмет возможности их использования при решении наиболее типовых задач географических исследований. Приведена классификация задач, алгоритмов и методов компьютерного зрения с точки зрения геоинформационных систем. Описаны возможные способы решения некоторых задач классификации и сегментации растровых изображений. Проанализированы наиболее популярные из них, включая такие, как использование сверточных и предобученных нейронных сетей для распознавания объектов на спутниковых снимках. Апробация прошла в рамках соревнования по векторизации объектов гидрографии и классификации объектов в открытом море Statoil/C-CORE Iceberg Classifier Challenge. В качестве исходных данных были взяты размеченные спутниковые снимки водной поверхности. Рассмотрены способы анализа пространственных данных и визуализации результатов с помощью пространственной автокорреляции по индексу Морана и расчета коэффициента Джини. Также были исследованы способы решения задач прогнозирования с использованием наиболее популярных алгоритмов регрессии, апробированные на примере определения положения координат дома и работы по временному ряду транзакций банкоматов и касс в пунктах сервиса. Для проведения данного исследования использовался набор данных всероссийского соревнования по машинному обучению Raiffeisen Data Cup. Произведено сравнение результатов работы алгоритмов машинного обучения с традиционными методами пространственного анализа. По результатам проведенных исследований были сформулированы выводы о применимости исследованных алгоритмов и технологий для конкретных географических задач с учетом зависимости результатов от типов используемых данных, требований к ресурсам, точности, универсальности.

КЛЮЧЕВЫЕ СЛОВА: машинное обучение, картография, сегментация, нейронные сети, регрессия, геоинформатика, спутниковые снимки.

¹ Сибирский государственный университет геосистем и технологий, ул. Плеханова, д. 10, 630108, Новосибирск, Россия, *e-mail*: alexeykw@mail.ru

² Сибирский государственный университет геосистем и технологий, ул. Плеханова, д. 10, 630108, Новосибирск, Россия, *e-mail*: it-technologies@yandex.ru

³ Сибирский государственный университет геосистем и технологий, ул. Плеханова, д. 10, 630108, Новосибирск, Россия, *e-mail*: komissarova_e@mail.ru

⁴ Сибирский государственный университет геосистем и технологий, ул. Плеханова, д. 10, 630108, Новосибирск, Россия, *e-mail*: helenkass@mail.ru

Alexey A. Kolesnikov¹, Pavel M. Kikin², Elena V. Komissarova³, Elena L. Kasyanova⁴

USE OF MACHINE LEARNING TECHNOLOGIES IN DECISION OF GEOINFORMATIONAL TASKS

ABSTRACT

Computer vision and data analysis are one of the most popular topics both among information technologies and most areas of scientific research. Geography, cartography and geoinformatics with their variety of types of source data, spatial analysis problems, visualization methods, modeling and forecasting methods cannot be better suited for using modern algorithms of machine learning. However, the use of these technologies rarely goes beyond the solution of private tasks of commercial campaigns and, often, is not widely publicized and any systematization or scientific description. In this respect, we decided to make a research of machine learning technologies in the context of using it while solving the most typical problems of geographical research. The classification of problems, algorithms and methods of computer vision from the point of view of geoinformation systems is given. Possible ways of solving some problems of classification and segmentation of raster images are described. The most popular of them are analyzed, including such as the use of convolutional and pre-conditioned neural networks for the recognition of objects on satellite images. The approbation took place within the competition in vectorization of hydrographic objects and the classification of objects in the open sea Statoil / C-CORE Iceberg Classifier Challenge. As initial data, we took marked satellite images of the water surface. The ways of spatial data analysis using the Moran index and calculating the Gini coefficient are considered. The methods of predicting the location of the coordinates of the house and work sudden user using the time series of ATM and cash register transactions at service points using regression algorithms were investigated. To conduct this study, the data set of the All-Russian competition in machine learning Raiffeisen Data Cup was used. We compared the results of usage of the machine learning algorithms and traditional methods of spatial analysis. Based on the results of the fulfilled investigations, we made the conclusions about the usability of the algorithms and technologies for specific geographic tasks, taking into account the dependence of the results from the types of using data used, resources requirements, accuracy, and universality.

KEYWORDS: machine learning, cartography, segmentation, neural networks, regression, geoinformatics, aerial images.

ВВЕДЕНИЕ

Машинное обучение и анализ данных являются одним из наиболее популярных и развивающихся направлений как в IT-индустрии, так и среди научных исследований.

В общем случае под машинным обучением понимается процесс улучшения производительности компьютерной программы при решении определенной задачи с учетом накопления опыта [Goodfellow et al., 2016; Mortensen et al., 2016].

¹ Siberian State University of Geosystems and Technologies, Plakhotnogo str., 10, 630108, Novosibirsk, Russia, *e-mail: alexeykw@mail.ru*

² Siberian State University of Geosystems and Technologies, Plakhotnogo str., 10, 630108, Novosibirsk, Russia, *e-mail: it-technologies@yandex.ru*

³ Siberian State University of Geosystems and Technologies, Plakhotnogo str., 10, 630108, Novosibirsk, Russia, *e-mail: komissarova_e@mail.ru*

⁴ Siberian State University of Geosystems and Technologies, Plakhotnogo str., 10, 630108, Novosibirsk, Russia, *e-mail: helenkass@mail.ru*

Наиболее популярными задачами машинного обучения, которые могут быть применены к исследованиям и использованию на практике в картографии и геоинформатике, являются [Benedetti, Rossini, 1993; Brown et al., 2002; Hariharan et al., 2014; Mortensen et al., 2016]:

- классификация – отнесение объекта к одной из категорий на основании его признаков; в качестве примеров можно привести разделение объектов на спутниковых снимках по типам, классификацию стран по демографическим показателям;
- регрессия – прогнозирование одного или нескольких количественных признаков объекта на основании набора прочих его признаков (как количественных, так и качественных), например, планирование показателей загрязнения территории, численности населения и т. п.;
- кластеризация – разбиение множества объектов на группы на основании признаков этих объектов так, чтобы внутри групп объекты были похожи между собой, а вне одной группы – менее похожи, причем количество групп заранее не известно; такой подход может применяться при поиске зависимостей между экономическими показателями, автоматизированном разбиении набора геологических скважин на группы по значениям показателей качества бурения;
- детекция аномалий – поиск объектов, сильно отличающихся от всех остальных в выборке либо от какой-то группы объектов, может применяться при поиске ошибок в таблицах семантических данных объектов, например, некорректных значений высоты горизонталей или отметок высот.

В зависимости от способа получения опыта (т. е. обработки новых блоков данных) алгоритмы машинного обучения разделяются на те, что обучаются «с учителем» (англ. supervised) и «без учителя» (англ. unsupervised learning)

В задачах обучения «без учителя» имеется выборка, состоящая из объектов, описываемых набором признаков. В задачах обучения «с учителем» вдобавок к этому для каждого объекта некоторой выборки, называемой обучающей, известен целевой признак, т. е. такой параметр, который хотелось бы прогнозировать для прочих объектов, не из обучающей выборки.

Рассмотрим несколько примеров решения геоинформационных задач методами машинного обучения.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

В качестве примера регрессии можно привести задачу, поставленную на конкурсе Raiffeisen Data Cup, проводимом Райффайзенбанком с 9 февраля по 23 марта 2018 г. на онлайн платформе Boosters.pro. Задача состояла в предсказании двух пар координат – для дома и работы по обезличенной истории транзакций при покупках и снятии наличных денег в банкомате. Среди предоставленной информации присутствовали координаты либо адрес банкомата, количество потраченных средств, валюта, дата транзакции и тому подобное. Метрикой качества является процент попаданий в окружность радиуса 0,02 градуса относительно координат дома и работы клиента (рис. 1).

Это соревнование представляет интерес с точки зрения следующих особенностей: традиционные алгоритмы регрессии предполагают прогнозирование одной числовой переменной, здесь же результатом будут являться две пары координат; поскольку в исходных данных присутствует информация о дате и времени события, то нужно учитывать не только пространственную, но и временную составляющую; поскольку отсутствовало примерно 30 процентов данных, то предобработка являлась очень важной составляющей успешного решения задачи. Для заполнения пропущенных значений использовались

как вычисления на основе существующих записей, так и данные из внешних источников, например, получение координат терминалов с помощью геокодирования адресов. Кроме традиционных статистических показателей для исследования исходных данных, содержащих объекты с пространственной привязкой, можно использовать специфические метрики – пространственный коэффициент Джини (англ. **Spatial Gini coefficient**) и **индекс Морана** (англ. **Moran's I Global Autocorrelation Statistic**) [Rey, Smith, 2013]. В общем виде обе метрики демонстрируют степень кластеризации пространственных объектов.



Рис. 1. Территориальное распределение точек, обозначающих транзакции
Fig. 1. Territorial distribution of transaction points

Авторами были выполнены наиболее простые варианты заполнения отсутствующих данных на основе существующих значений и с максимально возможным отсеиванием данных с пропусками. Выполнение расчетов пар координат осуществлялось на основе функции **Multi Output Regression** библиотеки **Scikit-Learn** для языка **Python**. В качестве алгоритмов расчета регрессии были использованы метод градиентного бустинга (реализация в программном обеспечении **xgBoost**) и **Random Forest** (библиотека **Scikit-Learn**) [Breiman, 2001; Bottou, 2010]. Использование метода градиентного бустинга для обоих предобработанных наборов исходных данных показало практически нулевую точность, «случайный лес» же показал значение 0,009125 для дополненных данных и 0,018875 для способа максимального отсеивания.

Далее рассмотрим задачу классификации. С точки зрения картографии и геоинформационных систем наиболее типовой задачей этой категории является распознавание объектов на изображениях, в качестве которых могут выступать спутниковые снимки, отсканированные тиражные оттиски на бумаге или пластике, абрисы геодезической съемки и т. п. В общем случае задачи технического зрения (к которым относится распознавание объектов) можно разделить на следующие категории:

– классификация – определение конкретного класса объекта на обрабатываемом изображении, т. е. на выходе формируется числовое или текстовое обозначение класса;

- классификация с локализацией – в результате обработки формируется обозначение класса и в виде векторной рамки, как правило прямоугольной (англ. bounding box), обозначается положение объекта на изображении;
- детектирование объектов – такой же принцип, что и в предыдущей категории, но детектируется и локализуется произвольное количество объектов на одном и том же изображении;
- семантическая сегментация (англ. semantic segmentation) – для каждого из пикселей обрабатываемого изображения формируется метрика, обозначающая его принадлежность к одному из заранее определенных классов [Hariharan et al., 2014; Hung, Ostermann, 2014; Mortensen et al., 2016];
- сегментация экземпляров (англ. instance segmentation) – логическое продолжение предыдущей категории, в этом случае из пикселей, относящихся к определенному классу, формируются отдельные растровые области, имеющие собственные контуры [Eigen,ergus, 2014; Hung, Ostermann, 2014].

Рассмотрим несколько методов машинного обучения на примере задач классификации (для определения типов видимых объектов в открытом море) и сегментации спутниковых снимков (применение алгоритмов сегментации при автоматизированной векторизации объектов гидрографии) в сравнении с традиционными ГИС-методами получения и анализа пространственной информации. Сначала рассмотрим задачу бинарной классификации объектов на спутниковых снимках.

В настоящее время многие учреждения и компании используют воздушную разведку для мониторинга условий окружающей среды и оценки рисков, связанных с айсбергами. Однако в отдаленных районах с особенно суровой погодой эти методы нецелесообразны, и единственным возможным вариантом мониторинга является использование данных со спутника. Компании Statoil и C-CORE запустили соревнование на платформе онлайн соревнований в области обработки данных [Kaggle.com](https://www.kaggle.com), чтобы открыть новые перспективы в отношении использования машинного обучения для более точного обнаружения и оценки представляемой угрозы от айсбергов как можно раньше. В этом соревновании предлагается построить алгоритм, который автоматически определяет, является ли дистанционно обнаруживаемая цель кораблем или айсбергом.

Для этого конкурса были предоставлены данные с двумя каналами: НН (передача и прием сигнала в горизонтальной поляризации) и НV (передача сигнала в горизонтальной поляризации, прием – в вертикальной). Это может сыграть важную роль в характеристиках объекта, поскольку объекты имеют тенденцию отражать излучение по-разному. Эти объекты можно визуально классифицировать, но основная проблема в очень большом количестве анализируемых изображений.

Данные (train.json, test.json) представлены в формате json (ознакомиться с его описанием можно на сайте [json.org](https://www.json.org)). Файлы состоят из наборов изображений, для каждого из которых указаны следующие поля:

- id – идентификатор изображения;
- band_1, band_2 – изображения в виде одномерного массива;
- inc_angle – угол падения, при котором был сделан снимок;
- is_iceberg – целевая переменная, существующая только в train.json, равная 1, если это айсберг, и 0, если это корабль.

Каждый канал имеет размер 75 на 75 пикселей, поэтому каждый элемент массива содержит 5625 элементов. Нужно отметить, что эти значения не являются традиционными для растровых изображений неотрицательными целыми числами, а представляют собой физические значения – это числа с плавающей точкой, показывающие уровень отраженного сигнала и измеряемые в децибелах. Полоса 1 (band_1) и полоса 2 (band_2) представ-

ляют собой сигналы, характеризующие обратное рассеяние сигнала спутника двух разных поляризаций с определенным углом падения. Поляризация соответствует HH (передача и прием в горизонтальной поляризации) и HV (передача сигнала в горизонтальной поляризации, прием – в вертикальной).




Рис. 2. Примеры изображений кораблей и айсбергов
Fig. 2. Examples of images of ships and icebergs

Суть исследования заключалась в сравнении ряда наиболее популярных методов машинного обучения большинства параметров, которые приняты по умолчанию на примере задач классификации растровых изображений. Поскольку практические результаты планируется использовать для классификации и сегментации объектов на видео для приложения дополненной реальности на мобильном устройстве, то в процессе исследования во внимание принималось не только точность, но и вычислительная емкость алгоритмов.

Одним из самых малозатратных, с точки зрения вычислительных ресурсов процессора, алгоритмов являются линейные модели, и для проведения эксперимента была выбрана логистическая регрессия. Тренировка заняла 218 секунд, предсказание 10,9 секунды, качество по метрике Logloss – 0,6984 и итоговое 1355 место.

Наиболее популярным способом повысить качество предсказания с минимумом изменений параметров обучающихся алгоритмов является ансамблирование. Суть этого подхода заключается в том, что по определенным правилам строится композиция алгоритмов, ошибки которых взаимно компенсируются. Правила оценки результатов каждого алгоритма строятся на основе схожести алгоритмов, размерах обучающей выборки, количестве признаков, их схожести и наличии или отсутствии выбросов в данных. Наиболее популярными правилами являются взвешенное среднее (упрощенный вариант смеси экспертов), бустинг («жадный» от англ. **greedy**), выбор алгоритма на текущем шаге, заключающийся в принятии локально оптимальных решений на каждом этапе, допуская, что конечное решение также окажется оптимальным, бэггинг (обучение на случайных подвыборках с повторениями из обучающей выборки), стекинг (использование набора предсказаний от алгоритмов на текущем шаге как вектора признаков для обобщающего метаалгоритма). Самым популярным алгоритмическим методом для задач машинного обучения разных типов является градиентный бустинг и его наиболее часто используемая реализация **xgBoost**. Суть градиентного бустинга состоит в построении ансамбля последовательно уточняющих друг друга элементарных моделей. Текущая элементарная модель обучается на ошибках ансамбля предыдущих моделей, ответы моделей взвешенно суммируются. Каждая последующая модель старается минимизировать значение функции потерь.

По результатам использования xgBoost тренировка заняла 186,5 секунды, предсказание – 14,2 секунды, качество по метрике Logloss – 0,2682 и итоговое 975 место.

В качестве логического продолжения предыдущего эксперимента были использованы две реализации градиентного бустинга в виде библиотек XGBoost и LightGBM. В качестве метода ансамблирования использовался бустинг, внутренней оценкой качества для обоих алгоритмов являлся logloss, и так же, как и в предыдущем варианте, использовалась кросс валидация с делением на три части. Для этого алгоритма тренировка заняла 2514,4 секунды, предсказание – 21,6 секунды, качество по метрике Logloss – 0,2021 и итоговое 536 место.

Далее приведем сводную таблицу результатов использования простых и предобученных сверточных нейронных сетей на базе Tensorflow.

Использование сверточных нейронных сетей
Comparison of the results of the use of convolutional neural networks

Тип сети	Время тренировки (секунды)	Время предсказания (секунды)	Logloss	Место
CNN	3800	39	0,2497	935
CNN+ VGG16	14 175	48	0,1745	304
CNN+ InceptionV3	15 867	53	0,1780	338

Опираясь на результаты замеров, приведенных в табл., можно сделать вывод, что если ориентироваться на использование нейронных сетей на стационарных компьютерах, то практически однозначно стоит отдать предпочтение использованию предобученных нейронных сетей для сокращения времени построения архитектуры.

Следующей задачей, которая будет рассмотрена в статье, является задача сегментации объектов гидрографии на спутниковых снимках Landsat с последующей векторизацией. Для оценки качества векторизации с помощью методов машинного обучения была выполнена векторизация объектов гидрографии вручную, принималась за эталон и затем сравнивалась с объектами, полученными с помощью методики NDVI [Peters et al., 2002] по космическому снимку и с помощью нейронной сети. Также для решения задачи автоматизированной классификации типов объектов гидрографии был использован метод дерева решений в качестве инструмента подбора наиболее оптимальных параметров классов [Benedetti, Rossini, 1993; Peters et al., 2002; Haug, Ostermann, 2014; Giusti et al., 2016].

В качестве исходных данных использовались снимки Landsat. В качестве тестового региона была взята территория Новосибирской области площадью 178 200 км². Из этой территории были выбраны участки, содержащие объекты гидрографии. Затем вручную средствами QGIS была выполнена разметка общего снимка. NDVI рассчитывался стандартным методом по инфракрасному и красному каналу Landsat 8 [Peters et al., 2002; Hariharan et al., 2014; Jia et al., 2014; Simonyan, Zisserman, 2014; Russakovsky et al., 2015].

Объекты гидрографии извлекались по значениям индекса от –0,25 до –0,5 и отобранным пикселям устанавливалась сплошная заливка. Настроенные таким образом пиксели затем инструментами QGIS собирались в полигоны (рис. 3).

Мера сходства, оцениваемая по коэффициенту Жаккара, составила примерно 65 процентов при настройках большинства инструментов QGIS по умолчанию.

Для работы с нейронными сетями использовалось программное обеспечение Keras с TensorFlow в качестве основной программной библиотеки и web-интерфейс Jupyter Notebook. Для начальных экспериментов нейронная сеть создавалась и обучалась без использования предобученных весов [Колесников и др., 2017; Haug, Ostermann, 2014].




Рис. 3. Векторные полигоны, полученные по NDVI растру
Fig. 3. Vector polygons obtained by NDVI raster

Для создания тренировочного набора общий космический снимок был разделен на 1000 растров в градациях серого и 1000 черно-белых растров (масок для обучения), полученных путем растеризации объектов гидрографии, которые были ранее вручную векторизованы. Размеры тренировочных элементов составляли 580 на 420 пикселей.

Для первого эксперимента использовались снимки в естественных цветах, которые конвертировались в градации серого на основе яркостного канала. Все объекты гидрографии была представлены в виде одного класса сегментации (рис. 4).




Рис. 4. Пример набора данных для обучения нейронной сети
Fig. 4. An example of a dataset for learning a neural network

Структурно сеть состоит из 9 сверточных слоев с функцией активации ReLU и полносвязного слоя для окончательного формирования картинки.

Для обучения сети и отображения меры сходства рассчитывается коэффициент Дайса. Все остальные настройки были использованы по умолчанию [Simonyan, Zisserman, 2014; Eigen, Fergus, 2015].

Результат после 20 эпох обучения и настроек сети по умолчанию – коэффициент потерь – 0,2421, коэффициент Дайса – 0,2421. Коэффициент Жаккара для этих параметров составил примерно 40 процентов за счет большого количества ложных срабатываний. Для того чтобы улучшить результат, были сделаны эксперименты с уменьшением в 2 раза размеров растров обучающей выборки (был получен эффект переобучения) и увеличением количества эпох до 30. В последнем варианте был получен наиболее качественный результат с коэффициентом Жаккара около 75 процентов. На рис. 5 приведены примеры работы сети и для сравнения результаты ручной разметки.




Рис. 5. Результаты сегментации для настроек по умолчанию, уменьшенных в два раза растров обучающей выборки, сети с 30 эпохами обучения и вручную размеченного фрагмента

Fig. 5. Segmentation results for the default settings, reduced by half the training sample size, the network with 30 learning epochs and manually marked fragment

После объединения элементов тестового растра инструментами QGIS выполнялась сборка полигонов и их разделение на реки и озера. Для разделения типов площадной гидрографии использовался алгоритм дерева решений в качестве исходных данных, для которого были использованы геометрические параметры объектов.

В QGIS в таблицу атрибутов были занесены числовые параметры для каждого объекта, такие как периметр, площадь, граничные координаты объектов, а также параметры, производные от базовых (рис. 6).

Для апробации метода была использована реализация деревьев решений из библиотеки Scikit-Learn. Максимальная глубина дерева менялась от 3 до 6 и точность по оценке `metrics.accuracy_score` от 0,976577 до 0,976889 соответственно для 30-процентной тестовой выборки. Такая высокая точность обусловлена несбалансированным количеством объектов разных типов. В варианте анализа гидрографических объектов на территории

Новосибирской области дерево решений с максимальной глубиной 3 было представлено следующим образом (рис. 7) [Колесников и др., 2017; Breiman, 2001].

Код	Тип	Соб_назв	Сост_об	X	Y	P	S	X_Y	type_num	
519	S0031131000	ВОДОХРАНИЛИЩА	Кривое	ДЕЙСТВУЮЩИЙ	0.026481	0.010828	0.105960	0.000040	2.445604	0
520	S0031131000	ВОДОХРАНИЛИЩА	Быструшка	ДЕЙСТВУЮЩИЙ	0.012124	0.004921	0.027331	0.000006	2.463727	0
521	S0031131000	ВОДОХРАНИЛИЩА	NaN	ДЕЙСТВУЮЩИЙ	0.003671	0.004749	0.012712	0.000004	0.773005	0
522	S0031131000	ВОДОХРАНИЛИЩА	NaN	ДЕЙСТВУЮЩИЙ	0.004869	0.005701	0.017294	0.000004	0.854061	0
523	S0031131000	ВОДОХРАНИЛИЩА	NaN	ДЕЙСТВУЮЩИЙ	0.001460	0.000867	0.003619	0.000001	1.683968	0

Рис. 6. Параметры объектов гидрографии
Fig. 6. Attributes of hydrographic objects

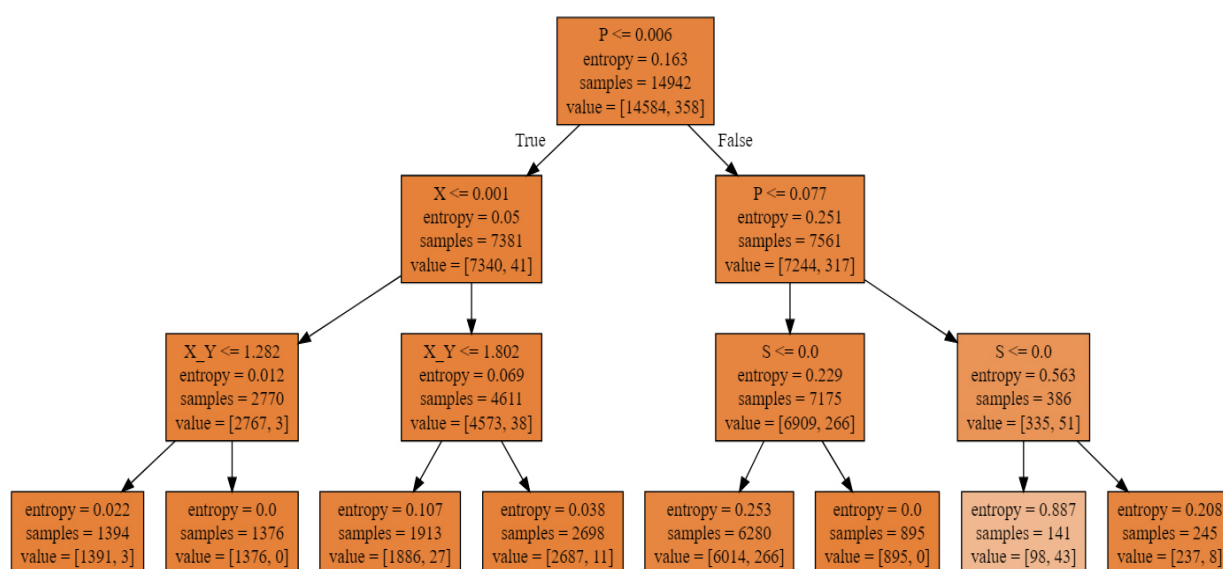


Рис. 7. Дерево решений для классификации объектов гидрографии
Fig. 7. The decision tree for the classification of hydrographic objects

С целью уменьшения переобучения на одном из типов объектов исходная обучающая выборка была откорректирована в сторону одинакового количества объектов разных типов. Наиболее оптимальным также оказалось дерево с максимальной глубиной 3 с точностью 0,862512.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

В результате исследования технологий машинного обучения можно сказать, что даже в варианте использования алгоритмов и программного обеспечения с большинством стандартных настроек можно получить результаты, сравнимые с результатами, получаемыми традиционными алгоритмическими методами.

Таким образом, для дальнейших исследований необходимо проанализировать результаты, получаемые с помощью дополнительной настройки (англ. fine-tuning) предобученных сетей, выполнить тренировку с перебором размера тренировочных растров, количеством и размерами полносвязных слоев, настройки типов пулинга после сверточных слоев [Колесников и др., 2017; Jia et al., 2014].

ВЫВОДЫ

По результатам проведенного исследования можно сделать следующие выводы: алгоритмические методы требуют меньших затрат по ресурсам для работы по сравнению с нейронными сетями, но чаще всего требуют больше операций по преобразовке и конвертации данных, из алгоритмических методов наиболее универсальным является градиентный бустинг, нейронные сети при настройках по умолчанию (особенно при использовании предобученных сетей) показывают лучшие результаты, но требуют много времени на подбор архитектуры сети и модели детектора в зависимости от задачи.

СПИСОК ЛИТЕРАТУРЫ

1. Колесников А.А., Кикин П.М., Комиссарова Е.В. Программирование для ГИС в рамках подготовки студентов, обучающихся по специальности «Информационные системы и технологии» // Актуальные вопросы образования. Ведущая роль университета в технической и кадровой модернизации российской экономики: Сб. материалов Междунар. науч.-методич. конф. В 3-х ч. Ч. 1. Новосибирск: СГУГиТ, 2015. С. 87–90.
2. Колесников А.А., Кикин П.М., Комиссарова Е.В. Создание виртуальных моделей местности и зданий // Интерэкспо ГЕО-Сибирь-2016. XII Междунар. науч. конгр., 18–22 апреля 2016 г., Новосибирск. Междунар. науч. конф. «Раннее предупреждение и управление в кризисных ситуациях в эпоху больших данных»: Сб. материалов. Т. 2. Новосибирск: СГУГиТ, 2016. С. 37–40.
3. Колесников А.А., Кикин П.М., Комиссарова Е.В. Использование открытых семантических баз данных для получения пространственной информации // Интерэкспо ГЕО-Сибирь-2017. XIII Междунар. науч. конгр., 17–21 апреля 2017 г., Новосибирск. Междунар. науч. конф. «Геодезия, геоинформатика, картография, маркшейдерия»: Сб. материалов. Т. 2. Новосибирск: СГУГиТ, 2017. С. 53–57.
4. Колесников А.А., Кикин П.М., Комиссарова Е.В., Грищенко Д.В. Использование машинного обучения для построения картографических изображений // Междунар. науч.-практ. конф. «От карты прошлого – к карте будущего», 28–30 ноября 2017 г., г. Пермь – г. Кудымкар. С. 110–120.
5. Badrinarayanan V., Kendall A., Cipolla R. Convolutional encoder-decoder architecture for image segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE Transactions on Pattern Analysis and Machine Intelligence. 39 (12), No 7803544. 2017. P. 2481–2495.
6. Benedetti R., Rossini P. On the use of NDVI profiles as a tool for agricultural statistics the case study of wheat yield estimate and forecast in Emilia Romagna // Remote Sensing of Environment. 1993. V. 45. P. 311–326.
7. Bottou L. Large-scale machine learning with stochastic gradient descent // Proceedings of COMPSTAT' 2010. Springer, 2010. P. 177–186.
8. Breiman L. Random forests // Machine learning. 2001. T. 45, No 1. P. 5–32.
9. Brown F.J., Reed C.B., Hayes J.M. et al. A prototype drought monitoring system integrating climate and satellite data. Proceedings of the Pecora L5/land satellite information 1V/ISPRS commission I/FIEOS. 2002. Colorado, USA.
10. Chen L.-C., Papandreou G., Kokkinos I. et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. arXiv preprint arXiv:1606.00915, 2016.
11. Dai J., He K., Sun J. Boxsup: Exploiting bounding boxes to supervise convolutional networks for semantic segmentation // Proceedings of the IEEE International Conference on Computer Vision. 2015. P. 1635–1643.

12. *Eigen D., Fergus R.* Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture // Proceedings of the IEEE International Conference on Computer Vision. 2015. P. 2650–2658; for Large-Scale Image Recognition, CoRR, vol. abs/1409.1556, 2014.
13. *Girshick R., Donahue J., Darrell T., Malik J.* Rich feature hierarchies for accurate object detection and semantic segmentation // Proceedings of the IEEE conference on computer vision and pattern recognition. 2014. P. 580–587.
14. *Giusti J. Guzzi, Cires D.C., He F.-L. et al.* A machine learning approach to visual perception of forest trails for mobile robots // IEEE Robotics and Automation Letters. 2016. T. 1, No 2. P. 661–667.
15. *Goodfellow I., Bengio Y., Courville A.* Deep Learning. MIT Press. 2016. 800 c. ISBN: 9780262035613.
16. *Hariharan B., Arbelaez P., Girshick R., Malik J.* Simultaneous detection and segmentation // European Conference on Computer Vision. Springer, 2014. P. 297–312.
17. *Haug S., Ostermann J.* A Crop Weed Field Image Dataset for the Evaluation of Computer Vision Based Precision Agriculture Tasks // Computer Vision – ECCV 2014 Workshops. Zurich: Springer, 2014. P. 105–116.
18. *Hung C., Nieto J., Taylor Z. et al.* Orchard fruit segmentation using multi-spectral feature learning // Intelligent Robots and Systems (IROS) IEEE/RSJ International Conference on. IEEE. 2013. P. 5314–5320.
19. *Jia Y., Shelhamer E., Donahue J. et al.* Caffe: Convolutional architecture for fast feature embedding. arXiv preprint arXiv: 1408.5093, 2014.
20. *Mitchell T.* Machine learning. McGraw-Hill, 1997. 414 c. ISBN: 0070428077.
21. *Mortensen K., Dyrmann M., Karstoft H. et al.* Semantic segmentation of mixed crops using deep convolutional neural network. International Conference on Agricultural Engineering, 2016.
22. *Peters J.A., Walter-Shea A.E., Ji L. et al.* Drought monitoring with NDVI-based standardized vegetation index // Photogrammetric Engineering and Remote Sensing. 2002. V. 68: 7175.
23. *Rey S. J., Smith R. J.* A spatial decomposition of the Gini coefficient // Letters in Spatial and Resource Sciences. 2013. V. 6. P. 55–70.
24. *Russakovsky O., Deng J., Su H. et al.* ImageNet Large Scale Visual Recognition Challenge // International Journal of Computer Vision (IJCV). 2015. T. 115, N 3. P. 211–252.
25. *Simonyan K., Zisserman A.* Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv technical report, eprint arXiv:1409.1556, 2014.

REFERENCES

1. *Badrinarayanan V., Kendall A., Cipolla R.* Convolutional encoder-decoder architecture for image segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE Transactions on Pattern Analysis and Machine Intelligence, 39 (12), No 7803544. 2017. P. 2481–2495.
2. *Benedetti R., Rossini P.* On the use of NDVI profiles as a tool for agricultural statistics the case study of wheat yield estimate and forecast in Emilia Romagna. Remote Sensing of Environment. 1993. V. 45. P. 311–326.
3. *Bottou L.* Large-scale machine learning with stochastic gradient descent. Proceedings of COMPSTAT' 2010. Springer, 2010. P. 177–186.
4. *Breiman L.* Random forests. Machine learning. 2001. T. 45, No 1. P. 5–32.
5. *Brown F.J., Reed C.B., Hayes J.M. et al.* A prototype drought monitoring system integrating climate and satellite data. Proceedings of the Pecora L5/land satellite information 1V/ISPRS commission I/FIEOS. 2002. Colorado, USA.

6. *Chen L.-C., Papandreou G., Kokkinos I. et al.* Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. arXiv preprint arXiv:1606.00915, 2016.
7. *Dai J., He K., Sun J.* Boxsup: Exploiting bounding boxes to supervise convolutional networks for semantic segmentation. Proceedings of the IEEE International Conference on Computer Vision. 2015. P. 1635–1643.
8. *Eigen D., Fergus R.* Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture. Proceedings of the IEEE International Conference on Computer Vision. 2015. P. 2650–2658; for Large-Scale Image Recognition, CoRR, vol. abs/1409.1556, 2014.
9. *Girshick R., Donahue J., Darrell T., Malik J.* Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition. 2014. P. 580–587.
10. *Giusti J. Guzzi, Cires D.C., He F.-L. et al.* A machine learning approach to visual perception of forest trails for mobile robots. IEEE Robotics and Automation Letters. 2016. V. 1, No 2. P. 661–667.
11. *Goodfellow I., Bengio Y., Courville A.* Deep Learning. MIT Press. 2016. 800 p. ISBN: 9780262035613.
12. *Hariharan B., Arbelaez P., Girshick R., Malik J.* Simultaneous detection and segmentation. European Conference on Computer Vision. Springer, 2014. P. 297–312.
13. *Haug S., Ostermann J.* A Crop Weed Field Image Dataset for the Evaluation of Computer Vision Based Precision Agriculture Tasks. Computer Vision – ECCV 2014 Workshops. Zurich: Springer, 2014. P. 105–116.
14. *Hung C., Nieto J., Taylor Z. et al.* Orchard fruit segmentation using multi-spectral feature learning. Intelligent Robots and Systems (IROS) IEEE/RSJ International Conference on. IEEE. 2013. P. 5314–5320.
15. *Jia Y., Shelhamer E., Donahue J. et al.* Caffe: Convolutional architecture for fast feature embedding. arXiv preprint arXiv: 1408.5093, 2014.
16. *Kolesnikov A.A., Kikin P.M., Komissarova E.V.* Using open semantic databases to obtain spatial information. Interekspo GEO-Sibir'-2017. XIII Mezhdunar. nauch. kongr., 17–21 aprelya 2017 g., Novosibirsk. Mezhdunar. nauch. konf. "Geodeziya, geoinformatika, kartografiya, marksheyderiya": V. 2. Novosibirsk: SSUGT, 2017. P. 53–57 (in Russian).
17. *Kolesnikov A.A., Kikin P.M., Komissarova E.V.* Creating virtual models of terrain and buildings. Interekspo GEO-Sibir'-2016. XII Mezhdunar. nauch. kongr., 18–22 aprelya 2016 g., Novosibirsk. Mezhdunar. nauch. Konf. "Raneye preduprezhdeniye i upravleniye v krizisnykh situatsiyakh v epokhu bol'shikh dannyykh": sb. materialov. V. 2. Novosibirsk: SSUGT, 2016. P. 37–40 (in Russian).
18. *Kolesnikov A.A., Kikin P.M., Komissarova E.V., Grishenko D.V.* Using machine learning for mapping. Mezhdunarodnaya nauchno-prakticheskaya konferentsiya "Ot karty proshlogo – k karte budushchego", 28–30 noyabrya 2017, g. Perm' – g. Kudymkar. P. 110–120 (in Russian).
19. *Kolesnikov A.A., Kikin P.M., Komissarova E.V.* Programming for GIS in the framework of the preparation of students studying in the specialty "Information Systems and Technologies". Aktual'nyye voprosy obrazovaniya. Vedushchaya rol' univ-ta v tekhn. i kadrovoy modernizatsii rossiyskoy ekonomiki: sb. mater. Mezhdunar. nauchno-metodich. konf. Part 1. Novosibirsk: SSUGT, 2015. P. 87–90 (in Russian).
20. *Mitchell T.* Machine learning. McGraw-Hill, 1997. 414 p. ISBN: 0070428077.
21. *Mortensen K., Dyrmann M., Karstoft H. et al.* Semantic segmentation of mixed crops using deep convolutional neural network. International Conference on Agricultural Engineering, 2016.

22. *Peters J.A., Walter-Shea A.E., Ji L. et al.* Drought monitoring with NDVI-based standardized vegetation index. *Photogrammetric Engineering and Remote Sensing*. 2002. V. 68: 7175.
23. *Rey S. J., Smith R. J.* A spatial decomposition of the Gini coefficient. *Letters in Spatial and Resource Sciences*. 2013. V. 6. P. 55–70.
24. *Russakovsky O., Deng J., Su H. et al.* ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*. 2015. V. 115, No 3. P. 211–252.
25. *Simonyan K., Zisserman A.* Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv technical report, eprint arXiv:1409.1556, 2014.