



УДК 004.8

DOI 10.33764/2411-1759-2023-28-4-5-11

Разработка алгоритма семантической сегментации на основе признаков для разделения наземных и наземных поверхностей

*А. А. Басаргин¹**

¹ Сибирский государственный университет геосистем и технологий, г. Новосибирск,
Российская Федерация

* e-mail: abaspirant@mail.ru

Аннотация. Последние достижения в области технологий дистанционного зондирования позволяют оцифровывать реальный мир почти автоматически. Результаты воздушного лазерного сканирования представляют собой тип данных с географической привязкой. Они предоставляют подробную трехмерную информацию об объектах и окружающей среде. Автоматизированная классификация и обнаружение объектов, полученных с помощью лидара, необходимы для минимизации производственных затрат. Хотя оптимизация традиционных методов с использованием алгоритмов, основанных на правилах, расширила геопространственные приложения, для получения высококачественного набора данных по-прежнему требуется значительное ручное редактирование. В отличие от изображений, массивы точек неструктурированы, разрежены и имеют нестандартный формат данных. Это создает множество проблем, но также предоставляет огромные возможности для захвата деталей сканируемых поверхностей с точностью до миллиметра. Классификация и отделение наземных точек от наземных значительно сокращает объемы данных для последовательного анализа поверхностей, что экономит время и упрощает дальнейший анализ. Основная идея научного исследования заключается в применении глубокого обучения как раздела машинного обучения для анализа массива точек. В статье представлен основанный на признаках алгоритм, который классифицирует наземные и наземные точки в массивах точек воздушного лазерного сканирования.

Ключевые слова: машинное обучение, глубокое обучение, искусственные нейронные сети, воздушное лазерное сканирование, оптимизатор Адама, двоичный классификатор, анализ главных компонент

Введение

Одним из главных направлений геоинформатики является исследование, разработка и реализация методов для решения задач распознавания образов. Задача распознавания образов является важной частью автоматизированных систем, систем управления и обработки информации и систем принятия решений. Классификация явлений, сигналов и предметов, которые определяются набором признаков и свойств, является задачей, находящей свое применение во многих отраслях, например, диагностической медицине, робототех-

нике, исследовании искусственного интеллекта, информационном поиске и др.

Методы машинного обучения автоматической классификации включают в себя хорошо известные методы, такие как методы опорных векторов и случайный вес. Однако их часто критикуют за ограниченные возможности обобщения из-за использования неглубоких архитектур нейронной сети.

Напротив, искусственные нейронные сети с несколькими скрытыми (внутренними) слоями используют так называемую глубокую архитектуру, которая применяется в последние годы с большим успехом. Основная про-

блема реализации метода контролируемого глубокого обучения заключается в том, что для настройки модели классификации требуется большое количество данных для обучения и проверки. Многие исследователи считают, что сквозной подход глубокого обучения может автоматически извлекать полезные функции из необработанных данных, и поэтому разработка функций не требуется, но это не всегда так [1–3].

Классификация – это систематическое распределение рассматриваемых предметов, процессов и явлений по родам, типам и видам по каким-либо значимым признакам [2].

В общей системе распознавания образов может присутствовать блок обучения, позволяющий по выборке обучающих образов, которым сопоставлен соответствующий класс, сформировать правила классификации.

Также по обучающей выборке может быть выбрано правило наиболее информативных признаков [3].

Автоматизированная классификация основывается на самообучении (объяснении). В данном случае количество априорной информации не позволяет сформировать словарь признаков, поэтому в систему вводится список правил, который объясняет задачи распознавания образов. Система распознавания, основываясь на данном наборе признаков, должна самостоятельно выделить словарь признаков и определить границы классов.

Автоматизированная классификация и обнаружение объектов данных лидара и изображений необходимы для минимизации производственных затрат. Хотя оптимизация традиционных методов с использованием алгоритмов, основанных на правилах, расширила геопространственные приложения, для получения высококачественного набора данных по-прежнему требуется значительное ручное редактирование. Извлечение значимой пространственной информации из огромного количества данных имеет решающее значение и требует эффективного и точного рабочего процесса обработки.

В статье исследуется использование функций, которые могут эффективнее решать проблемы классификации при использовании меньшего количества ресурсов, то есть не-

большого количества слоев и меньшего количества обучающих данных. Однако реализация метода глубокого обучения на основе признаков требует четкого понимания как проблемы, так и структуры данных для использования функций распознавания [4].

Методы и материалы

Для работы со сверточными нейронными сетями использовалось программное обеспечение Matlab R2016a и встроенная библиотека ConvolutionNeuralNetwork. Сред разработки Matlab имеет хороший функционал для визуализации и анализа изображений (Image Processing Toolbox) и позволяет быстро и легко исследовать разные конфигурации нейронных сетей.

Структура алгоритма представляет собой основанный на признаках подход, который помечает наземные и наземные точки, полученные по результатам воздушного лазерного сканирования (ВЛС). Исходные данные для этого исследования получены на основе набора данных бортового лидара с открытым доступом. Реализация метода глубокого обучения, основанного на функциях, требует четкого понимания как проблемы, так и структуры данных.

Для получения качественных результатов при обучении нейронной сети необходимо подобрать репрезентативные данные, т. е. чтобы выборка обладала достаточным количеством разнообразных данных, в которых нейронная сеть смогла бы выделить необходимые признаки для дальнейшей классификации объектов [5–8].

Для характеристики качества обучения использовалась общепринятая метрика – точность классификации, т. е. соотношение количества правильно классифицированных массивов точек из выборки к размеру самой выборки.

В качестве отправной точки была взята простая конфигурация нейронной сети (рис. 1), которую будем называть исходной конфигурацией, состоящая из входного слоя размером 20×20 , сверточного слоя размером фильтра 3×3 и количества фильтров, равного 16, слоя пулинга (maxpool) 2×2 , полносвязанного слоя, состоящего из 62 нейронов (по количеству клас-

сов), и слоя softmax, который определяет, к какому классу относится точка [9–11].

Данная конфигурация показала точность классификации 50 % (0,5099).

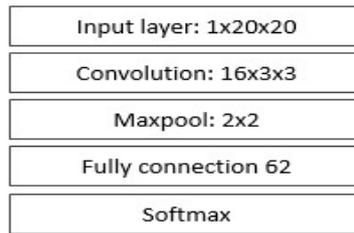


Рис. 1. Стартовая конфигурация

Предлагаемый алгоритм состоит из двух шагов. На первом этапе выполняется проектирование и извлечение признаков, а на втором – разрабатывается архитектура глубокого обучения (рис. 2).

Особенности классификации получаются с использованием сферических и цилиндрических окрестностей каждой точки данных. Сферическая окрестность с заданным пользователем радиусом используется для получения трехмерных геометрических признаков на основе ковариационной матрицы, сгенерированной координатами соседних точек (x, y, z).

Анализ главных компонент выполняется для оценки собственных значений и векторов из ковариационной матрицы, которые используются для получения необходимых функций. Наиболее распространенными трехмерными признаками, также известными как ковариационные признаки, являются: нормаль точки, кривизна, три собственных значения координат, линейность, планарность, рассеяние, всевариантность, собственная энтропия.

Вертикальная цилиндрическая окрестность (с тем же радиусом, что и сферическая)

используется для получения цилиндрических элементов, которые связаны с высотами точек [12–15].

Предлагаемая архитектура глубокого обучения разрабатывается с помощью двоичного классификатора и следует прямому процессу создания искусственной нейронной сети. Входными данными для сети являются векторы признаков, а выходными – метки заземления (1) или отсутствия заземления (0).

Полносвязные сетевые слои используются с функцией активации для скрытых слоев, а сигмовидная функция используется для выходного слоя.

В качестве функции потерь используется бинарная перекрестная энтропия, а использование оптимизатора Адама ускоряет процесс обучения модели.

Сеть состоит из пяти скрытых слоев по 50 нейронов в каждом. Входные данные обрабатываются с помощью мини-пакета из 128 нейронов. Сеть обучается на 50 эпохах, и в качестве окончательной модели выбирается та, которая обеспечивает наибольшую точность.

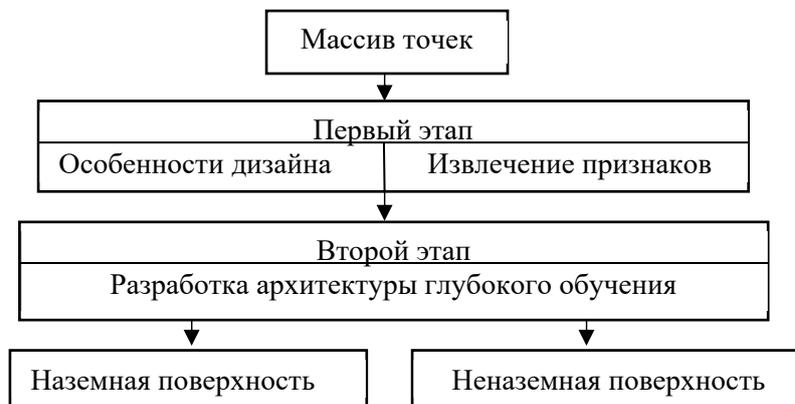


Рис. 2. Рабочий процесс алгоритма глубокого обучения

Результаты

Разработанный алгоритм можно продемонстрировать на основе набора данных бортового лидара с открытым доступом. Средняя плотность точек, горизонтальная и вертикальная точность данных $15/\text{м}^2$, ± 3 см и ± 6 см соответственно. Данные организованы в «плитки» размером 500×500 м, каждая из которых содержит в среднем 5–7 млн точек.

Точки разбиты на классы, например, почва, растительность, здания, вода, мосты, линии электропередачи и неклассифицированные. Дополнительное ручное редактирование было выполнено для получения более точной классификации данных по наземным и неназемным точкам.

Для использования алгоритма были выбраны две плитки из пригородного района. Набор тестовых данных имеет разницу в высоте около 20 м между самой высокой и самой низкой точками.

Одна из выбранных «плиток» использовалась для обучения и проверки, а часть другой плитки была выбрана в качестве тестовых данных (рис. 3). «Плитка» для обучения была разделена на пять сегментов, и один из них был случайным образом выбран в качестве проверочного набора. Наборы для обучения, проверки и тестирования состоят из 3 481 758, 650 764 и 970 387 баллов соответственно. Требуемые входные векторы были сгенерированы с размером окрестности радиусом 100 см, и предложенный алгоритм был применен с использованием различных комбинаций признаков [16].



Рис. 3. Массив точек трехмерного лазерного сканирования, используемый в качестве тестового набора данных

Он состоит из набора 16 векторов признаков: нормаль точки, кривизна, линейность, планарность, рассеяние, собственная энтропия, смещение плоскости, вертикальность, высота точки, диапазон, среднее, дисперсия, плотность точек, положительная открытость, коэффициент эха и интенсивность [17].

Алгоритм достигал наивысшей точности 99,77 % для извлечения поверхности земли, оценки $F1$ 97,5 и 97,8 % для маркировки наземных и неназемных точек соответственно и общей точности модели 97,7 % (рис. 4).

Обсуждаемый подход может быть успешным в качестве так называемого метода «рабочей лошади» для эффективного отделения наземных и неназемных точек. Он сочетает в себе высокую точность с относительно низкой вычислительной нагрузкой. Это отличает метод от недавних сквозных методов облака точек глубокого обучения, которые обычно требуют серьезного обучения, и поэтому их труднее выполнять на стандартном настольном компьютере (рис. 5).



Рис. 4. 2D-график наземных данных для тестового набора данных, показывающий наземные (небесно-голубые) и наземные (желтые) точки

Описанный здесь сквозной подход принимает более информативные входные данные (т. е. векторы признаков) и, следовательно, требует меньше внутренних слоев. Как

следствие, необходимо определить меньшее количество параметров (т. е. веса нейронных связей), что делает метод намного легче и эффективнее [18].

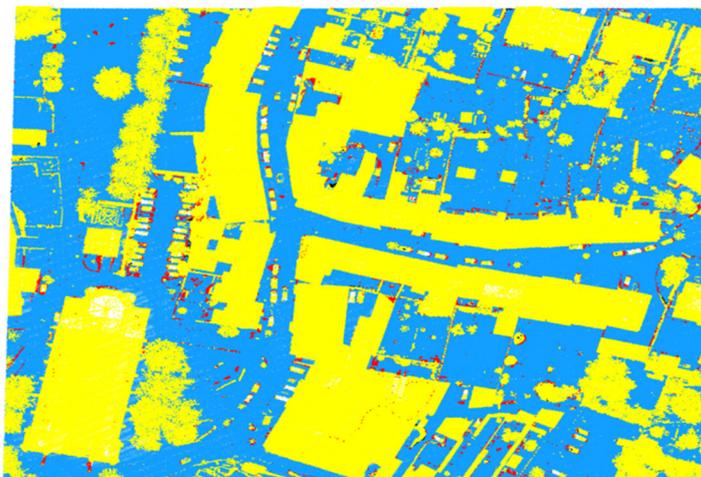


Рис. 5. 2D-график результатов классификации набора тестовых данных, показывающий правильные наземные точки (небесно-голубые), правильные наземные точки (желтые) и неправильно классифицированные точки (красные и черные)

Заключение

Предлагаемый алгоритм глубокого обучения на основе признаков классифицирует наземные и наземные точки, полученные по результатам лазерного сканирования с высокой степенью точности. Он представляет полностью подключенный подход к глубокой нейронной сети для разработки бинарного классификатора.

В отличие от большинства алгоритмов, основанных на признаках, новый алгоритм не требует многомасштабных окрестностей.

Следовательно, он может значительно снизить вычислительную сложность и сэкономить время по сравнению со многими существующими алгоритмами на основе признаков.

Данный алгоритм классификации прост, но эффективен в работе. Это связано с тем, что архитектура неглубокая, но мощная, что снижает вычислительную нагрузку и эффективно извлекает как наземные, так и неназемные точки при наличии крутых склонов, неровной местности и значительной изменчивости высоты.

Однако предлагаемый алгоритм глубокого обучения на основе признаков требует понимания как признаков значимости, используемых в качестве входных векторов, так и свойств данных для настройки параметров в процессе построения модели для достижения максимальной точности классификации.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Аджич Г. Как повысить эффективность программных продуктов и проектов по их разработке. – М. : Альпина Паблишер, 2017. – 235 с.
2. Артемов А. Информационная безопасность. – М. : Академия безопасности и выживания, 2014. – 340 с.
3. Баженова И. Ю. Основы проектирования приложений баз данных. – М. : Национальный Открытый Университет «ИНТУИТ», 2016. – 238 с.
4. Билгин К. Освоение кросс-платформенной разработки с помощью Xamarin. – М. : Пакт, 2016. – 390 с.
5. Болодурина И. П. Системный анализ. – Оренбург : ОГУ, 2013. – 193 с.
6. Гаврилова И. В. Разработка приложений. – М. : ФЛИНТА, 2017. – 243 с.
7. Гуцин А. Н. Базы данных : учеб.-метод. пособие. – М. : Директ-Медиа, 2015. – 311 с.
8. Ерохин В. В., Погонишева Д. А. Безопасность информационных систем. – М. : ФЛИНТА:Наука, 2016. – 666 с.
9. Замай С. С., Якубайлик О. Э. Программное обеспечение и технологии геоинформационных систем : учеб. пособие. – Красноярск : Красноярск. гос. ун-т., 2015. – 110 с.
10. Избачков Ю., Петров В. Информационные системы. – СПб. : Питер, 2011. – 224 с.
11. Крючкова Л. А., Самоделькин Л. А., Степанова А. С. и др. Интеллектуальные технологии в геоинформационных системах : учеб. пособие. – Меганьютон. : BSUIR, 2018. – 359 с.
12. Исаев Г. Н. Проектирование информационных систем : учеб. пособие. – М. : Омега-Л, 2012. – 432 с.
13. Кремер Н. Ш., Путко Б. А., Фридман М. Н. Исследование операций в экономике : учеб. пособие для вузов / под ред. проф. Н. Ш. Кремер. – М. : ЮНИТИ, 2015 – 407 с.
14. Кара-Ушанов В. SQL – язык реляционных баз данных. – М. : ФЛИНТА, 2017. – 210 с.
15. Качала В. В. Теория систем и системный анализ. – М. : Горячая Линия-Телеком, 2013. – 272 с.
16. Кольцов А. С., Федорков Е. Д. Геоинформационные системы : учеб. пособие. – Воронеж : Воронежский гос. техн. ун-т, 2016. – 203 с.
17. Рыбаков М. Бизнес-процессы. Как их описать, отладить и внедрить. – М. : Дрофа, 2016. – 570 с.
18. Разработка мобильных приложений: с чего начать [Электронный ресурс]. – Режим доступа: <https://habr.com/company/mailru/blog/179113/>.

Об авторах

Андрей Александрович Басаргин – кандидат технических наук, доцент кафедры прикладной информатики и информационных систем.

Получено 01.03.2023

© А. А. Басаргин, 2023

Development of a feature-based semantic segmentation algorithm for separating terrestrial and non-terrestrial surfaces

A. A. Basargin^{1}*

¹Siberian State University of Geosystems and Technologies, Novosibirsk, Russian Federation

*e-mail: abaspirant@mail.ru

Abstract. Recent advances in remote sensing technology make it possible to digitize the real world almost automatically. Airborne laser scan results are georeferenced data type. They provide detailed 3D information about objects and the environment. Automated classification and detection of objects obtained from lidar is necessary to

minimize production costs. Although the optimization of traditional methods using rule-based algorithms has expanded geospatial applications, significant manual editing is still required to obtain a high quality data set. Unlike images, point arrays are unstructured, sparse, and have a non-standard data format. This creates a lot of challenges, but it also provides a huge opportunity to capture the details of scanned surfaces with millimeter accuracy. Classifying and separating non-ground points from ground points greatly reduces the amount of data required for consistent surface analysis, saving time and simplifying further analysis. The main idea of scientific research is to use deep learning as a section of machine learning to analyze an array of points. The paper presents a feature-based algorithm that classifies ground and non-ground points in airborne laser scanning cloud.

Keywords: machine learning; deep learning; algorithm architecture; airborne laser scanning; Adam optimizer; binary classifier; principal component analysis

REFERENCES

1. Adzic, G. How to improve the efficiency of software products and projects for their development / G. Adzic. – M.: Alpina Publisher, 2017. – 235 p.
2. Artemov, A. Information security / A. Artemov. - M.: Academy of security and survival, 2014. - 340 p.
3. Bazhenova, I. Yu. Fundamentals of designing database applications / I. Yu. Bazhenova. - M.: National Open University "INTUIT", 2016. - 238 p.
4. Bilgin, K. Mastering cross-platform development with Xamarin / K. Bilgin. – M.: Pakt, 2016. – 390 p.
5. Bolodurina, I. P. System analysis / I. P. Bolodurina. - Orenburg: OGU, 2013. - 193 p.
6. Gavrilova, I. V. Application Development / I. V. Gavrilova. - M: FLINTA, 2017. - 243 p.
7. Gushchin, A. N. Databases: teaching aid / A. N. Gushchin. – M.: Direct-Media, 2015. – 311 p.
8. Erokhin, V. V. Security of information systems / V. V. Erokhin, D. A. Po-gonysheva. - M.: FLINTA: Nauka, 2016. - 666 p.
9. Zamai, S. S. Software and technologies of geoinformation systems: Proc. allowance / S. S. Zamai, O. E. Yakubailik. - Krasnoyarsk. state un-t. Krasnoyarsk, 2015. - 110 p.
10. Izbachkov, Yu., Petrov V. Information systems / Yu. Izbachkov, V. Petrov. - St. Petersburg: Peter, 2011. - 224 p.
11. Kryuchkova L.A., Samodelkin L.A., Stepanova A.S. [et al.] Intelligent technologies in geoinformation systems: textbook. – Meganewton.: BSUIR, 2018. – 359 p.
12. Isaev, G. N. Design of information systems: account. allowance / G. N. Is-aev. – M.: Omega-L, 2012. – 432 p.
13. Research operations in the economy: Uch. Manual for universities / N. Sh. Kremer, B. A. Putko, M. N. Fridman; Under the editorship of Prof. N. Sh. Kremer. – M.: UNITI, 2015 – 407p.
14. Kara-Ushanov, V. SQL - the language of relational databases / V. Kara-Ushanov. - M: FLINTA, 2017. - 210 p.
15. Kachala, V. V. Theory of systems and system analysis / V. V. Kachala. - M.: Hot Line-Telecom, 2013.- 272 p.
16. Koltsov, A. S. Geoinformation systems: textbook. allowance /A. S. Koltsov, E. D. Fedorkov. - Voronezh: GOUVPO "Voronezh State Technical University", 2016. - 203 p.
17. Rybakov, M. Business processes. How to describe, debug and implement them / M. Rybakov. - M.: Drofa, 2016. - 570 p.
18. Development of mobile applications: where to start [Electronic resource]. – Access mode: <https://habr.com/company/mailru/blog/179113/>. - Zagl. from the screen.

Author details

Andrey A. Basargin – Ph. D., Associate Professor, Department of Applied Informatics and Information Systems.

Received 01.03.2023

© A. A. Basargin, 2023