

ОПРЕДЕЛЕНИЕ ОПТИМАЛЬНОЙ АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ ДЛЯ ПОИСКА СТЫКОВЫХ НАКЛАДОК ЖЕЛЕЗНОДОРОЖНОГО ПУТИ

Н.Е. Маренов

nikitam5497@gmail.com

SPIN-код: 9727-4590

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

Аннотация

Использование глубоких нейронных сетей в настоящее время является одним из самых популярных подходов к созданию автоматизированных систем. Сверточные нейронные сети применяются в задачах классификации изображений. Автоматизация контроля состояния железнодорожного пути необходима для бесперебойного движения транспорта, поэтому решение задачи обнаружения дефектов с использованием нейронных сетей является актуальной. В статье определена оптимальная архитектура нейронной сети для поиска стыковых накладок, состоящая из семи слоев. Рассмотрено влияние размера подаваемых изображений и количества слоев Convolution – ReLU – Max Pooling на скорость обработки изображений и ошибки классификации.

Ключевые слова

Сверточная нейронная сеть, глубокое обучение, машинное обучение, классификация изображений, распознавание образов, железнодорожный путь, стыковая накладка, обнаружение дефектов

Поступила в редакцию 15.05.2020

© МГТУ им. Н.Э. Баумана, 2020

Введение. Основным условием эксплуатации железных дорог, перевозки пассажиров и грузов является безопасность движения поездов [1, 2]. В связи с этим важно решить задачу автоматизации контроля состояния элементов строений железнодорожного пути [3–6].

Железнодорожный путь состоит из верхнего и нижнего строений. На нижнем строении размещается верхнее строение. Последнее, в свою очередь, предназначено для направления движения и передачи нагрузки от колес подвижного состава. На рис. 1 показана структурная схема верхнего строения. К элементам верхнего строения относятся:

- балластный слой;
- рельсы и стрелочные переводы;
- шпалы;
- рельсовые скрепления, позволяющие соединять рельсы друг с другом и прикреплять их к шпалам.

Рельсовый стык — самое напряженное место пути. Это объясняется тем, что при проходе подвижного состава в местах стыков увеличивается ударно-динамическое воздействие на путь. В связи с этим важен контроль накладок, устанавливаемых в местах стыковых скреплений и предназначенных для восприятия изгибающего момента и поперечной силы. Поэтому необходимо решить задачу поиска накладок.




Рис. 1. Структура верхнего строения железнодорожного пути

В рамках настоящей статьи для решения задачи предлагается использовать алгоритмы глубокого обучения. Глубокое обучение (*Deep Learning*) является областью машинного обучения (*Machine Learning*) и предназначено для решения задач с использованием глубоких нейронных сетей.

Сверточные нейронные сети. Сверточные нейронные сети (*Convolutional Neural Network* — *CNN*) входят в состав технологий глубокого обучения. Они достаточно эффективно применяются в настоящее время в задачах компьютерного зрения, в том числе и для решения задач классификации изображений [7]. Простым примером нейронной сети для классификации изображений служит архитектура, показанная на рис. 2.




Рис. 2. Архитектура для классификации изображений

Слой *Input* (входные данные) содержит исходную информацию об анализируемом изображении.

В слое *Convolution* (слой свертки) происходит выделение признаков на входном изображении и формирование карты признаков. В данном слое осуществляется свертка входного набора данных с фильтрами.

В слое *ReLU* (блок линейной ректификации) применяется поэлементная функция активации, устанавливающая нулевой порог. Эта функция преобразует взвешенную сумму в выходной сигнал нейрона.

Слой *Max Pooling* (слой пулинга) выполняет операцию по понижающей дискретизации пространственных размеров (ширина и высота), в результате чего объем может сократиться. На этом этапе выполняется нелинейное уплотнение карты признаков путем вычисления максимального значения в каждом регионе карты.

Слой *Fully Connected* (полносвязный слой) выводит N -мерный вектор (N — число классов) для определения нужного класса. Работа организуется путем обращения к выходу предыдущего слоя (карте признаков) и определения свойств, которые наиболее характерны для определенного класса.

В слое *Softmax* осуществляется активация выходного слоя.

Classification output layer — слой классификации [8].

После нескольких прохождений слоев *Convolution* – *ReLU* – *Max Pooling* изображение перестраивается от конкретного набора пикселей к более аб-

страктным картам признаков, а также после прохождения каждого слоя происходит уменьшение размера карт признаков.

Данная работа посвящена определению оптимальной архитектуры сети для поиска накладок.

Данные для классификации. В качестве исходных данных для разметки использована запись 87 км железнодорожного пути. Запись содержит 694 изображений накладок, которые являются положительными примерами, и 31 824 отрицательных примеров, являющихся изображениями других элементов верхнего строения железнодорожного пути. На основе записи были получены отдельные изображения, отсортированные по категориям: «накладка» (положительные примеры) и «не накладка» (отрицательные примеры). На рис. 3 показаны примеры изображений.




Рис. 3. Пример изображений:

a — накладка; *б* — не накладка

Обучение нейронной сети — изменение поведения сети вследствие изменений внешней среды. В процессе обучения определяются веса связей между нейронами. Целью обучения является достижение некоторого заданного уровня точности.

На входной слой подаются изображения, уменьшенные до одинакового размера. В слое свертки происходит оптимизация размера фильтра и количества фильтров. Оптимальными значениями оказались:

- размеры фильтров от 3×3 до 5×5;
- количество фильтров от 15 до 30;
- слой пулинга с размером пула 2×2 и шагом 2;
- полносвязный слой с числом нейронов 2 и слоем классификации с двумя выходными классами.

Также осуществляется оптимизация параметров для тренировки сети:

- InitialLearnRate — начальный темп обучения в диапазоне от 0,0005 до 0,03;
- LearnRateDropFactor фактор отбрасывания темпа обучения от 0,40 до 0,99;
- MiniBatchSize — размер мини-пакета в каждой учебной итерации от 1 до 128 элементов.

Результаты экспериментов. Неверное определение накладки будем называть ошибкой первого рода, пропуск накладки — ошибкой второго рода.

Количество стыковых скреплений на 1 км пути зависит от радиуса кривизны участка и от количества переводов на пути. Существуют бесстыковые рельсовые плети длиной 30 км и больше, их укладывают на прямых участках пути и кривых участках радиусом не менее 350 м. При меньших радиусах кривизны или наличии переводов используют скрепления с помощью накладок. В связи с этим очень важно не пропускать накладки. Таким образом, ошибка второго рода должна быть минимальной.

Для уменьшения ошибки второго рода, связанной с малым количеством данных для обучения, был реализован алгоритм с использованием перекрестной проверки.

Перекрестная проверка (Cross-validation) — метод оценки аналитической модели и ее поведения на независимых данных. При оценке модели данные разбиваются на k частей. Затем на $k - 1$ частях данных осуществляется обучение модели, а оставшаяся часть данных используется для тестирования. Процедура повторяется k раз; таким образом каждая из k частей данных используется для тестирования. В результате получается оценка эффективности выбранной модели с наиболее равномерным использованием имеющихся данных [9, 10].

Обучение проводилось на машине с 4-ядерным процессором с тактовой частотой 3,9 ГГц, графическим процессором 1050ti и оперативной памятью 16 Гб.

Определим размер, до которого следует уменьшать изображения, подаваемые на входной слой. В табл. 1 приведены результаты обучения при условии, что архитектура сети соответствует показанной на рис. 2.

Таблица 1

Влияние размера изображений, подаваемых на входной слой, на результаты классификации

Размер	Скорость обработки, изображений/с	Ошибки первого рода, %	Ошибки второго рода, %
60×10	261,6	0,98	2,12
120×20	288,5	0,33	0,0
180×30	278,3	0,63	2,12
240×40	264,1	0,53	3,19

Оптимальным размером изображения, подаваемого на входной слой, является 120×20. При иных размерах изображений увеличивается ошибка второго рода и уменьшается скорость обработки изображений.

Определим оптимальное количество слоев Convolution – ReLU – Max Pooling при условии, что на входной слой подаются изображения, уменьшенные до размера 120×20 (табл. 2).

**Влияние количества слоев Convolution – ReLU – Max Pooling
на результаты классификации**

Количество слоев Convolution – ReLU – Max Pooling	Скорость обработки, изображений/с	Ошибки первого рода, %	Ошибки второго рода,%
1	288,5	1,23	0,0
2	287,1	1,87	2,12

Согласно результатам, приведенным в табл. 2 при количестве слоев Convolution – ReLU – Max Pooling равным единице, скорость обработки изображений выше, а ошибки первого и второго родов меньше.

Оптимальная архитектура сети для поиска накладок показана на рис. 4.

ANALYSIS RESULT				
	NAME	TYPE	ACTIVATIONS	LEARNABLES
1	imageinput 20x120x1 images with 'zerocenter' ...	Image Input	20x120x1	-
2	conv 15 5x5x1 convolutions with stride [1 ...	Convolution	16x116x15	Weights 5x5x1x15 Bias 1x1x15
3	relu ReLU	ReLU	16x116x15	-
4	maxpool 2x2 max pooling with stride [2 2] an...	Max Pooling	8x58x15	-
5	fc 2 fully connected layer	Fully Connected	1x1x2	Weights 2x6960 Bias 2x1
6	softmax softmax	Softmax	1x1x2	-
7	classoutput crossentropyex	Classification Output	-	-

Рис. 4. Архитектура рассчитанной сети

Как видно, рассчитанная сверточная нейронная сеть состоит из семи слоев: слой входных данных, слой свертки, слой ReLU, слой пулинга, полносвязный слой, слой активации и слой классификации.

Заключение. В настоящей статье была определена оптимальная архитектура нейронной сети для поиска стыковых накладок. Сеть состоит из семи слоев:

- слой входных данных — монохромные изображения размером 120×20;
- слой свертки — 15 фильтров размером 5×5 с шагом 1;
- слой ReLU;
- слой пулинга размером 2×2;
- полносвязный слой — 2 класса;
- слой активации;
- слой классификации.

В текущей выборке для обучения недостаточно данных, содержащих изображения объектов, перекрывающих накладки. В дальнейшем предполагается оценка эффективности работы сети в режиме реальной работы системы контроля верхнего строения железнодорожного пути.

Литература

- [1] Яковлева Т.Г., ред. Железнодорожный путь. М., Транспорт, 1999.
- [2] Шахунянц Г.М. Железнодорожный путь. М., Транспорт, 1987.
- [3] Sadeghi J., Askarinejad H. Application of neural networks in evaluation of railway track quality condition. *J. Mech. Sci. Technol.*, 2012, vol. 26, no. 1, pp. 113–122. DOI: <https://doi.org/10.1007/s12206-011-1016-5>
- [4] Nakhaee M.Ch., Hiemstra D., Stoelinga M., et al. The recent applications of machine learning in rail track maintenance: a survey. *Proc. RSSRail*, 2019, pp. 91–105. DOI: https://doi.org/10.1007/978-3-030-18744-6_6
- [5] Gibert X., Patel V., Chellappa R. Deep multitask learning for railway track inspection. *IEEE Trans. Intell. Transp. Syst.*, 2017, vol. 18, no. 1, pp. 153–164. DOI: <https://doi.org/10.1109/TITS.2016.2568758>
- [6] Mittal Sh., Rao D. Vision based railway track monitoring using deep learning. *arxiv.org: веб-сайт*. URL: <https://arxiv.org/abs/1711.06423> (дата обращения: 15.02.2020).
- [7] Николенко С., Кадури А., Архангельская Е. Глубокое обучение. СПб., Питер, 2019.
- [8] Свёрточные нейронные сети: взгляд изнутри. *ru.datasides.com: веб-сайт*. URL: <http://ru.datasides.com/code/cnn-convolutional-neural-networks/> (дата обращения 16.12.2019).
- [9] Cawley G., Talbot N. On over-fitting in model selection and subsequent selection bias in performance evaluation. *J. Mach. Learn. Res.*, 2010, no. 11, pp. 2079–2107.
- [10] Hastie T., Tibshirani R., Friedman J. The elements of statistical learning. Springer, 2009.

Маренов Никита Евгеньевич — студент кафедры «Лазерные и оптико-электронные системы», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Научный руководитель — Родионов Евгений Витальевич, преподаватель кафедры «Лазерные и оптико-электронные системы», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Ссылку на эту статью просим оформлять следующим образом:

Маренов Н.Е. Определение оптимальной архитектуры нейронной сети для поиска стыковых накладок железнодорожного пути. *Политехнический молодежный журнал*, 2020, № 06(47). <http://dx.doi.org/10.18698/2541-8009-2020-06-618>

DETERMINATION OF THE OPTIMAL NEURAL NETWORK ARCHITECTURE FOR THE SEARCH FOR THE RAILWAY FISHPLATES

N.E. Marenov

nikitam5497@gmail.com

SPIN-code: 9727-4590

Bauman Moscow State Technical University, Moscow, Russian Federation

Abstract

The use of deep neural networks is currently one of the most popular approaches to creating automated systems. Convolutional neural networks are used in image classification problems. Automation of monitoring the condition of the railway track is necessary for the smooth movement of transport, therefore, the solution of the problem of detecting defects using neural networks is relevant. The article defines the optimal architecture of the neural network for the search for fishplates, consisting of seven layers. The influence of the size of the submitted images and the number of Convolution – ReLU – Max Pooling layers on the image processing speed and classification errors is considered.

Keywords

Convolutional neural network, deep learning, machine learning, image classification, pattern recognition, rail, fishplates, defect detection

Received 15.05.2020

© Bauman Moscow State Technical University, 2020

References

- [1] Yakovleva T.G., ed. Zheleznodorozhnyy put' [Railway]. Moscow, Transport Publ., 1999. (in Russ.).
- [2] Shakhunyan G.M. Zheleznodorozhnyy put' [Railway]. Moscow, Transport Publ., 1987. (in Russ.).
- [3] Sadeghi J., Askarinejad H. Application of neural networks in evaluation of railway track quality condition. *J. Mech. Sci. Technol.*, 2012, vol. 26, no. 1, pp. 113–122. DOI: <https://doi.org/10.1007/s12206-011-1016-5>
- [4] Nakhaee M.Ch., Hiemstra D., Stoelinga M., et al. The recent applications of machine learning in rail track maintenance: a survey. *Proc. RSSRail*, 2019, pp. 91–105. DOI: https://doi.org/10.1007/978-3-030-18744-6_6
- [5] Gibert X., Patel V., Chellappa R. Deep multitask learning for railway track inspection. *IEEE Trans. Intell. Transp. Syst.*, 2017, vol. 18, no. 1, pp. 153–164. DOI: <https://doi.org/10.1109/TITS.2016.2568758>
- [6] Mittal Sh., Rao D. Vision based railway track monitoring using deep learning. *arxiv.org: website*. URL: <https://arxiv.org/abs/1711.06423> (accessed: 15.02.2020).
- [7] Nikolenko S., Kadurin A., Arkhangel'skaya E. Glubokoe obuchenie [Deep learning]. Sankt-Petersburg, Piter Publ., 2019 (in Russ.).
- [8] Svertochnye neyronnye seti: vzglyad iznutri [Convolutional neural networks: an outward glance]. *ru.datasides.com: website* (in Russ.). URL: <http://ru.datasides.com/code/cnn-convolutional-neural-networks/> (accessed: 16.12.2019).
- [9] Cawley G., Talbot N. On over-fitting in model selection and subsequent selection bias in performance evaluation. *J. Mach. Learn. Res.*, 2010, no. 11, pp. 2079–2107.
- [10] Hastie T., Tibshirani R., Friedman J. The elements of statistical learning. Springer, 2009.

Marenov N.E. — Student, Department of Laser and Optoelectronic Systems, Bauman Moscow State Technical University, Moscow, Russian Federation.

Scientific advisor — Rodionov E.V., Lecturer, Department of Laser and Optoelectronic Systems, Bauman Moscow State Technical University, Moscow, Russian Federation.

Please cite this article in English as:

Marenov N.E. Determination of the optimal neural network architecture for the search for the railway fishplates. *Politekhicheskiy molodezhnyy zhurnal* [Politechnical student journal], 2020, no. 06(47). <http://dx.doi.org/10.18698/2541-8009-2020-06-618.html> (in Russ.).