

Технологии информационного общества

## ОБРАБОТКА РАЗНОРОДНОЙ ИНФОРМАЦИИ С ПОМОЩЬЮ ГЛУБОКОГО ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ

Статья рекомендована к публикации членом редакционного совета А.Н. Райковым 25.01.2020

**Потемкин Алексей Владимирович**

*Кандидат технических наук  
Академия ФСО России  
Орел, Российская Федерация  
alex.potemkin85@mail.ru*

### Аннотация

*В работе предлагается архитектура нейронной сети для обработки разнородной информации. Предложенная архитектура включает отдельные входы для текстовой, графической, табличной, графовой и мета информации. Проведено экспериментальное исследование показателей эффективности разработанной архитектуры для решения задачи выявления информационных операций в сети Интернет.*

### Ключевые слова

*разнородная информация, нейронные сети, глубокое обучение, универсальная архитектура*

Методы глубокого обучения нейронных сетей используются для решения многих задач обработки данных [1]. Для решения ряда реальных практических задач необходимо производить анализ информации, представленной в различных форматах (тексты, графы, изображения, таблицы), а современные архитектуры нейронных сетей эффективно работают только с данными в заданном формате и решают достаточно узкую задачу [2-4]. Решением данной проблемы может быть создание универсальной архитектуры, имеющей отдельные входы для различных видов информации: текстовой, видео, аудио, графической, табличной, графовой и т.д. Однако использование сложной многоформатной архитектуры потребует ресурсов нескольких датацентров для ее обучения. Крупные компании, использующие глубокое обучение нейронных сетей для решения прикладных задач, добились больших успехов как в разработке архитектур нейронных сетей, так и в их обучении. Научные коллективы образовательных учреждений, коммерческих компаний предлагают для открытого использования не только исходные коды компонентов анализа данных, но и предоставляют значения весовых коэффициентов нейронной сети, обученной на миллионах примерах данных с использованием дорогостоящего оборудования датацентров. Использование весовых коэффициентов позволяет дообучать классификатор для решения какой-либо прикладной задачи, добавляя новые выходные слои с использованием техники «замораживания» весовых коэффициентов первичных слоев нейронной сети. Это позволяет существенно снизить ресурсоемкость обучения глубоких архитектур нейронных сетей, повысить их результативность, а в случае решения задачи обработки разнородной информации обеспечить саму возможность обучения столь сложного классификатора.

В последнее десятилетие процесс анализа данных в режиме онлайн набирает популярность. Люди, занимающиеся подготовкой аналитических статей, имеют широкий выбор источников информации: от печатных изданий до пользовательских сообщений в социальных медиа. Обзор официальных изданий несет характер ручного поиска, обладает высокой степенью структурированности, за которой может быть завуалирована неявная проблематика.

Эффективность нейронных сетей возрастает из-за их возможности обучаться на примерах и умения делать собственные выводы к дальнейшей работе, а также в увеличении скорости обработки данных с помощью графических ускорителей и специализированных платформ. Различные методики в сфере нейронных сетей позволяют осуществлять сбор и анализ графической, мультимедийной и текстовой информации. Но так как это представляет собой разрозненный

---

© Потемкин А.В., 2020. Производство и хостинг журнала «Информационное общество» осуществляется Институтом развития информационного общества.

Данная статья распространяется на условиях международной лицензии Creative Commons «Атрибуция — Некоммерческое использование — На тех же условиях» Всемирная 4.0 (Creative Commons Attribution – NonCommercial - ShareAlike 4.0 International; CC BY-NC-SA 4.0). См. <https://creativecommons.org/licenses/by-nc-sa/4.0/legalcode.ru>

процесс, то каждый элемент сопровождения главной темы исследования будет представлять собой отдельную структуру. Для полноценного анализа социальных медиа предлагается объединить все методы нейронных сетей, чтобы их работа проходила параллельно и объединялась на определенном этапе. Преимущества данной идеи в том, что полноценный анализ представленной информации позволяет ассоциировать весь контент целиком без потери информативности.

Для обработки разнородной информации с помощью глубокого обучения нейронных сетей предлагается архитектура с отдельными входами для каждого вида источника (рис. 1), объединяющая выходы предварительных слоев. В состав предварительных слоев нейронной сети включены существующие архитектуры, эффективнее других обрабатывающих определенный тип информации. В результате строится пространство признаков для объектов анализа независимо от формата исходной информации.

Ключевой проблемой использования подобных архитектур для обработки информации является высокая ресурсоёмкость ее обучения. Эту проблему предлагается решать, обучая отдельно существующие нейронные сети для обработки определенного формата информации и включая ее в общую архитектуру с «замороженными» нижними слоями. Под «заморозкой» слоев нейронной сети понимается фиксация ее весовых коэффициентов без возможности их изменения в процессе обучения. Данный прием позволяет обучить модель предварительной обработки определенного типа информации для извлечения максимального количества признаков. После включения данной модели в общую архитектуру с «замороженными» нижними слоями будет происходить обучение только внешнего слоя модели, определяющего как рассчитанные признаки влияют на возможность отнесения к тому или иному классу. Таким образом, количество параметров, изменяющихся в процессе обучения всей архитектуры, будет на несколько порядков меньше всех параметров составляющих ее моделей.

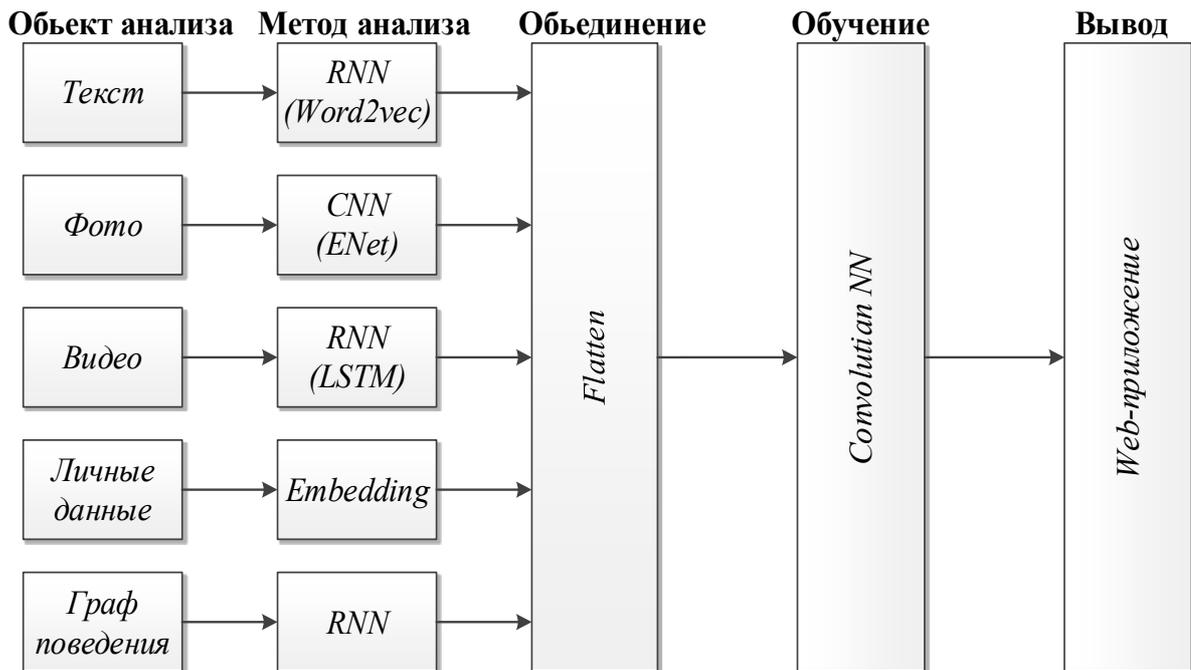


Рис. 1. Универсальная архитектура обработки разнородной информации

Подробное описание существующих архитектур нейронных сетей представлено в [5]. Объединяются выходные данные предварительных слоев в специальном слое нейронной сети, который называется Flatten. На выходе данного слоя получается одномерный вектор, полученный слиянием одномерных векторов выхода каждого предварительного слоя. При этом если какой-либо слой возвращает многомерную последовательность, то перед объединением она преобразуется в одномерную.

Для работы с текстами предлагается строить пространство признаков с помощью модели word2vec. На вход сверточной нейронной сети (Convolution Neural Network или сокращенно CNN) подается предложение, в котором каждое слово уже представлено вектором.

Из всего многообразия видов нейронных сетей наилучшие результаты в задачах обработки изображений показывают сверточные сети [6], обладающие устойчивостью к масштабированию, смещению, искажению изображения. Исходные данные разбиваются на сетку типа «квадрат» для дальнейшего сканирования определенной области через наложения ядра и пропускания на следующий слой. Следует отметить, что область в масштабе одной плоскости имеют одинаковые синаптические коэффициенты для связывания локальных участков предыдущего слоя. Выделяют два вида чередующихся между собой слоев:

- основной или сверточный, на котором происходит перенос исходного изображения;
- подвыборочный, который уменьшает масштаб и набор плоскостей для анализа изображения.

Таким образом входные данные разбиваются на плоскости каждого сверточного слоя, которые выстраиваются в иерархию, представляя собой «слоеный пирог».

Когда ненастроенной сети предъявляется входной образ, она выдает некоторый случайный выход. Функция ошибки представляет собой разность между текущим выходом сети и идеальным выходом, который необходимо получить. Для успешного обучения сети требуется приблизить выход сети к желаемому выходу, т. е. последовательно уменьшать величину функции ошибки. Это достигается настройкой межнейронных связей. Каждый нейрон в сети имеет свои веса, которые настраиваются, чтобы уменьшить величину функции ошибки.

Для устранения выделения неправильной области идентификации изображения используют следующие операции с нейронной сетью:

1. Масштабирование относительно одного размера изображения.
2. Сканирование нейросетью изображения и выделение участков-кандидатов на определение лица человека.
3. Все найденные участки масштабируются относительно исходного изображения: наиболее совпавшие участки называются истинными, а наименьшие – ложными. Последние участки не рассматриваются в дальнейшем анализе.

После определения лица на изображении необходимо присвоить его определенному человеку для этого собирается база данных лиц, на основе которых происходит обучение нейронной сети с учителем.

В дальнейшем этот алгоритм способствует быстрой классификации изображений, например, касающихся высших должностных лиц, которые упоминаются в социальных сетях.

В качестве сверточных сетей предлагается использовать слои на основе технологии ResNet от компании Microsoft, которая обладает уровнем ошибок равный 3,57%. Более эффективна сеть ENet, в значительной степени основанная на ResNet. Это сводится к структуре с одним мастером и несколькими ветвями, которые отделяются от мастера, но также объединяются посредством поэлементного добавления. Работает в 18 раз быстрее, требует в 75 раз меньше FLOP, имеет в 79 раз меньше параметров и обеспечивает схожую или лучшую точность для существующих моделей.

Рекуррентная нейронная сеть (RNN) отличаются от традиционных искусственных нейронных сетей наличием обратных связей (как внутри, так и между слоями), что позволяет при анализе текущего набора входных значений учитывать результаты предыдущих итераций. Данная особенность позволяет говорить о наличии «эффекта памяти», позволяющего анализировать последовательности подаваемых на вход данных.

Рекуррентная нейронная сеть с «долгой краткосрочной памятью» - это специфическая модификация классической РНС, которая способна учитывать долгосрочные зависимости между подаваемыми на вход данными (в обычных рекуррентных нейронных сетях при увеличении расстояния между двумя подаваемыми на вход последовательностями данных зависимость ослабевает), что достигается за счёт того, что LSTM ячейка не использует функцию активации внутри своих рекуррентных слоёв. Это приводит к тому, что важные значения не размываются во времени при использовании метода обратного распространения ошибки при обучении сети. Важная информация поступает в запоминающую ячейку и удаляется оттуда в соответствии с заранее заданными правилами.

Обучение происходит на основе выделения фона и основных действий для классификации видео. Для уменьшения объема происходит перевод в последовательность векторов с помощью алгоритмов поиска дескрипторов.

Далее, для каждого кадра составляется «справочник», состоящий из близлежащих дескрипторов. Затем, для каждого видео связываются одинаковые значения из «справочников»

изображений одного видео и составляется «мешок слов», который представляет собой упорядоченный массив из наиболее часто встречающихся дескрипторов (визуальный контент) и массив смещений (набор переходов между кадрами). Полученные «мешки слов» являются набором базовых движений. Теперь необходим классификатор. Рекуррентная нейронная сеть с LSTM-ячейкой способна работать с длинными последовательностями данных, поэтому был выбран этот классификатор. Далее, такая нейронная сеть обучалась методом обратного распространения ошибки по времени. На вход сети подавались видео из обучающей выборки представленные «мешками слов», и на выходе были известны классы, к которым принадлежали эти видео. После некоторого числа итераций (подбирается эмпирически), обученный классификатор, которому на вход подаётся видео (в формате «мешка слов»), должен выдать вероятностную принадлежность тому или иному известному классу.

Для оценки результативности предложенных решений был проведен эксперимент по анализу разнородной информации предложенной архитектурой. Весовые коэффициенты предварительных слоев были получены из открытых источников или обучены отдельно на массиве данных соответствующего формата. В ходе эксперимента решалась задача распознавания информационных операций в социальных сетях Интернет. В работе [7] представлен подход к распознаванию информационных операций в средствах массовой информации сети Интернет на основе заранее выбранных признаков. При этом обрабатывалась только текстовая и графовая информация.

Задача распознавания информационных операций относится к классу бинарной классификации, где один класс будет обозначать наличие информационной операций, а другой — ее отсутствие. Для обучения нейронных сетей с целью бинарной классификации целесообразно использовать в качестве функции потерь перекрёстную энтропию, а сигмоиду в качестве функции активации последнего (выходного) слоя нейронной сети.

В ходе проведения эксперимента на вход нейронной сети подавались сообщения из социальной сети «Вконтакте», представленные в текстовом, графическом, аудио, видео формате, а также структуры распространения информации в виде графов. Обучение нейронной сети проводилось с применением языка программирования Python и библиотеки Tensorflow. Так как данная библиотека использует тензоры в процессе расчета весовых коэффициентов модели, целесообразно применять тензорные процессоры (GPU), работающие на большинстве задач обучения нейронных сетей в 2-3 раза быстрее современных графических процессоров.

Результаты точности обучения и ошибки предсказания в течение 1000 эпох обучения представлены на рисунке 2.

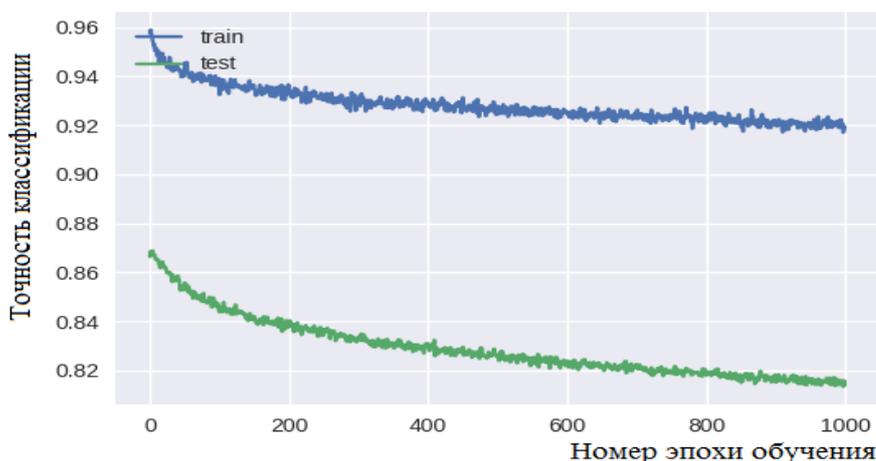


Рис. 2. Зависимость точности классификации данных на обучающей выборке и тестовом наборе от номера эпохи обучения

В силу высокой стоимости обучения универсальной архитектуры на большом количестве разнородной информации обучение в течение нескольких тысяч эпох является направлением дальнейших исследований.

Однако в результате проверки на данных, которые нейронной сети не предоставлялись, точность выявления информационных операций в социальной сети Интернет составила 81,7%. Метод распознавания информационных операций, представленный в работе [7], на тех же

выборках данных показал точность 53,3%. Достаточно низкая точность в данном случае объясняется прежде всего учетом только текстовых сообщений. Таким образом, предложенная универсальная архитектура нейронной сети для обработки разнородной информации позволяет решать различные практические задачи классификации данных с высокими показателями результативности. Проблему высокой ресурсоемкости обучения предложенной архитектуры нейронной сети частично можно решать использованием предобученных классификаторов для определенного типа информации с последующим дообучением верхних слоев нейронной сети и «замораживанием» нижних. Обучение нейронной сети на современных тензорных процессорах GPU также позволило существенно повысить скорость обучения.

## Литература

1. Lee J. H., Shin J., Realf M. J. Machine learning: Overview of the recent progresses and implications for the process systems engineering field //Computers & Chemical Engineering. – 2018. – Т. 114. – С. 111-121.
2. Тетерин Д. А., Хабибулин Р. Ш., Гудин С. В. Обзор применения искусственных нейронных сетей в управлении социальными и экономическими системами //Научные ведомости Белгородского государственного университета. Серия: Экономика. Информатика. – 2018. – Т. 45. – № 3.
3. Гончаров И. В., Паринов П. А., Сирота А. А. Моделирование процессов информационно-психологического воздействия в социальных сетях. Вестник ВГУ, Серия: Системный анализ и информационные технологии, 2018, № 2– 2018. с. 93-104.
4. Аветисян А. А., Дробышевский М. Д., Турдаков Д. Ю. Методы анализа информационных потоков в сети Интернет //Труды института системного программирования РАН. – 2018. – Т. 30. – № 6. – С. 199-220.
5. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей //СПб.: Питер. – 2018.
6. Друки А. А. Система поиска, выделения и распознавания лиц на изображениях //Известия Томского политехнического университета. Инжиниринг георесурсов. – 2011. – Т. 318. – № 5. – С. 64–70.
7. Потемкин А. В. Распознавание информационных операций средств массовой информации сети Интернет //Интернет-журнал Науковедение. – 2015. – Т. 7. – № 3 (28).

# PROCESSING COMPLEX INFORMATION USING THE DEEP LEARNING OF NEURAL NETWORKS

**Potemkin Alexey Vladimirovich**

*Candidate of technical sciences*

*Academy of Federal Security Service of Russia*

*Oryol, Russian Federation*

*alex.potemkin85@mail.ru*

## Abstract

*The paper proposes a neural network architecture for processing heterogeneous information. The proposed architecture includes separate inputs for text, graphic, tabular, graph and meta information. An experimental study of the efficiency indicators of the developed architecture for solving the problem of identifying information operations on the Internet is carried out.*

## Keywords

*complex information, neural networks, deep learning, multipurpose architecture*

## References

1. Lee J. H., Shin J., Realf M. J. Machine learning: Overview of the recent progresses and implications for the process systems engineering field //Computers & Chemical Engineering. – 2018. – T. 114. – S. 111-121.
2. Teterin D. A., Khabibulin R. SH., Gudim S. V. Obzor primeneniya iskusstvennykh neyronnykh setey v upravlenii sotsial'nymi i ekonomicheskimi sistemami //Nauchnyye vedomosti Belgorodskogo gosudarstvennogo universiteta. Seriya: Ekonomika. Informatika. – 2018. – T. 45. – №. 3.
3. Goncharov I. V., Parinov P. A., Sirota A. A. Modelirovaniye protsessov informatsionno-psikhologicheskogo vozdeystviya v sotsial'nykh setyakh. Vestnik VGU, Seriya: Sistemnyy analiz i informatsionnyye tekhnologii, 2018, № 2– 2018. s. 93-104.
4. Avetisyan A. A., Drobyshevskiy M. D., Turdakov D. YU. Metody analiza informatsionnykh potokov v seti Internet //Trudy instituta sistemnogo programmirovaniya RAN. – 2018. – T. 30. – №. 6. – S. 199-220.
5. Nikolenko S., Kadurin A., Arkhangel'skaya Ye. Glubokoye obucheniye. Pogruzheniye v mir neyronnykh setey //SPb.: Piter. – 2018.
6. Druki A. A. Sistema poiska, vydeleniya i raspoznavaniya lits na izobrazheniyakh //Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov. – 2011. – T. 318. – №. 5. – C. 64-70.
7. Potemkin A. V. Raspoznavaniye informatsionnykh operatsiy sredstv massovoy informatsii seti Internet //Internet-zhurnal Naukovedeniye. – 2015. – T. 7. – №. 3 (28).