

УДК 004.85

ТЕХНОЛОГИИ ГЛУБИННОГО ОБУЧЕНИЯ В НЕЙРОННЫХ СЕТЯХ

Бородин А. Ф.,

студент 2 курса магистратуры

Московский государственный технический университет им. Н. Э. Баумана

Россия, г. Москва

Аннотация

В данной статье рассматриваются существующие технологии глубинного обучения в нейронных сетях. Также приводятся классы задач, решаемые приведенными технологиями.

Ключевые слова: нейронная сеть, глубинное обучение, CNN, RNN

DEEP LEARNING TECHNOLOGIES IN NEURAL NETWORKS

Borodin A. F.,

master student,

Bauman Moscow State Technical University

Russian Federation, Moscow

Annotation

This article discusses deep learning technologies in neural networks. The classes of problems solved by the given technologies are also given.

Keywords: neural network, deep learning, CNN, RNN

Глубинное обучение (от англ. Deep learning) — совокупность методов машинного обучения (с учителем, с частичным привлечением учителя, без

учителя, с подкреплением), основанных на обучении представлениям (от англ. feature/representation learning), а не специализированным алгоритмам под конкретные задачи [1]. Строго говоря, глубинное обучение – область машинного обучения, связанная с алгоритмами, вдохновленными организацией структуры человеческого мозга, представленной в виде совокупности нейронов, называемой нейронными сетями.

Простейшие модели искусственных нейронов, впервые были представлены в работе Уоррена Мак-Калока и Уолтера Питтса в 1943 году. Их работа “Логическое исчисление идей, относящихся к нервной активности”, заложила основы разработки моделей машинного обучения в рамках решения задач искусственного интеллекта.

Сверточные нейронные сети, являются явным примером сетей с глубинным обучением. Сверточные нейронные сети представляют собой нейронные сети, используемые, прежде всего, для классификации изображений и выполнения распознавания объектов внутри изображений. Модели сверточных нейронных сетей позволяют идентифицировать лица, уличные знаки и многие другие классы визуальных данных. Архитектура примера модели сверточной нейронной сети представлена на рисунке 1.

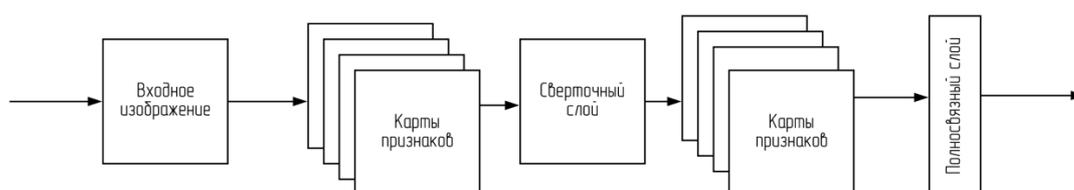


Рисунок 1 – Архитектура сверточной нейронной сети

В отличие от других алгоритмов и моделей нейронных сетей, сверточные нейронные сети обрабатывают изображения в виде трехмерных матриц. Каждый пиксель исходного изображения представляется в виде слоев каналов трех цветов – красного, зеленого и синего. Таким образом изображение поступает на

вход сверточной нейронной сети в виде матрицы размерности $M \times N \times 3$, где M и N являются шириной и высотой изображения. В ходе выполнения операции свертки происходит поэлементное умножение и сложение элементов сверточного ядра и исходного изображения, результатом которого является изображение, подающееся на следующий слой нейронной сети. Слои пулинга (от англ. Pooling), уменьшают размерность карт признаков, работая по принципу сверточного слоя, они вычисляют среднее, или наибольшее/наименьшее значение среди пикселей исходной карты и формируют новую, с меньшей размерностью. Последним слоем CNN является полносвязный слой. На входы каждого из нейронов полносвязного слоя подаются все выходы предыдущего слоя. Число нейронов в последнем слое CNN равняется числу классов, к которым изначально было необходимо отнести исходные изображения. После обработки значений взвешенной суммы сигналов функцией активации, на выходе нейронная сеть формирует вероятностный вектор. Сумма всех элементов вектора равняется единице. Строго говоря, значения элементов векторов говорят о том, с какой вероятностью исходное изображение можно отнести к данному классу.

RNN или рекуррентные нейронные сети являются разновидностью нейронных сетей, которые используют выходной сигнал с предыдущей итерации в качестве входного на последующей итерации. Таким образом можно сказать, что RNN обладают памятью. Модель одного нейрона в рекуррентной нейронной сети представлена на рисунке 2.

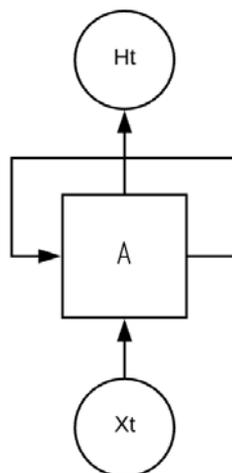


Рисунок 2 – Модель нейрона в RNN

Нейрон принимает на вход сигналы с предыдущего слоя нейронной сети и результат предыдущего прохождения данных через него. Данная разновидность нейронных сетей используется в задачах обработки и генерации текста. Строго говоря, используя “память”, нейронная сеть может анализировать фрагменты текста опираясь на предыдущие. Передача информации от одной итерации к другой позволяет находить зависимости в тексте и предсказывать последующие комбинации слов и предложения.

Однако, во время работы, RNN могут забывать весь текст, который проходил через слой нейронов с памятью и получается, что нейронная сеть “забывает” предыдущие отрывки текста и в процессе генерации текста опирается только на несколько слов из предыдущей итерации, в то время как для генерации длинных осмысленных предложений необходима связь между словами и фразами, расположенными на большем расстоянии. Для решения так называемой, проблемы потери контекста, подходят LSTM-сети.

LSTM-сети являются разновидностью рекуррентных нейронных сетей, способной к обучению на долгосрочных зависимостях (от англ. Long-term dependencies). Впервые, LSTM-сети были представлены в работе Сеппа Хохрайтера и Юргена Шмидхубера в 1997 году. В отличие от рекуррентных нейронных сетей, LSTM-сеть можно использовать при решении задач

классификации, обработки и прогнозирования временных рядов в случаях, когда важные события разделены временными лагами с неопределённой продолжительностью и границами. LSTM-сеть содержит LSTM-модули, способные запоминать значения на короткие и длинные промежутки времени.

LSTM-модуль состоит из нескольких ячеек памяти. Каждая из ячеек памяти имеет на выходе два состояния, переносящиеся в следующее: текущее состояние ячейки и ее скрытое состояние. Блоки памяти отвечают за запоминание некоторого объема данных, а манипуляция с этими данными осуществляется тремя, так называемыми “гейтами” (от англ. Gate). Гейт забывания отвечает за удаление информации из состояния ячейки. Информация, которая больше не требуется для LSTM для понимания вещей или информации, которая имеет меньшее значение, удаляется путем умножения фильтра. Это необходимо для оптимизации производительности LSTM-сети. Входной гейт отвечает за добавление информации в текущее состояние ячейки. Выходной гейт отвечает за формирование выходного сигнала ячейки памяти.

Капсульные нейронные сети впервые были представлены в работе Джеффри Хинтона в 2017 году. Исследование данной области и представление капсульных нейронных сетей обусловлено проблемами классических нейронных сетей – они не учитывают различные ракурсы объектов и относительное расположение объектов в пространстве изображения. Таким образом, на рисунке 3 показан пример двух изображений, одно из которых неверно классифицируется классической нейронной сетью как человеческое лицо.

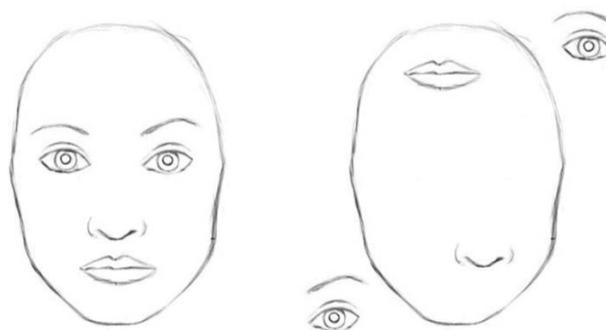


Рисунок 3 – Пример неверно распознанного сверточной нейронной сетью изображения

Проблема заключается в том, что работа нейронов в полносвязных слоях не учитывает различного положения и ракурса объектов в пространстве. Для решения данной проблемы, в сверточных нейронных сетях используются слои пулинга, уменьшающие размерность данных, что позволяет формировать более точные карты признаков, учитывающие более крупные признаки на изображениях. На такое высокое значение точности распознавания в существующих сверточных нейронных сетях влияют большие размеры обучающих выборок. Однако, подбор больших объемов обучающих выборок не всегда возможен, эту проблему так же решают предложенные Джеффри Хинтоном CapsNN.

Нейронная сеть в данном случае, согласно Хинтону, состоит из двух частей – шифратора и дешифратора (от англ. Encoder and decoder). Первым из слоев шифратора является слой свертки, его основной задачей является нахождение основных признаков на изображениях. Далее расположены слои капсул. Капсулы в CapsNN нужны для генерации и обучения дополнительных наборов признаков. Механизм капсул реализован с модификацией исходных карт признаков с помощью матричных преобразований. Строго говоря, с помощью капсул увеличивается число инвариантов, которое сеть может распознавать и генерировать.

Таким образом, в статье были рассмотрены несколько моделей глубинного обучения, например рекуррентные, капсульные, LSTM нейронные сети и некоторые классы задач, решаемые этими моделями: распознавание образов, классификация изображений и составление осмысленного текста.

Библиографический список

1. Deep Learning [Электронный ресурс]. – Режим доступа – URL: https://ru.wikipedia.org/wiki/Глубокое_обучение (Дата обращения 24.08.2018)
2. Deep Learning in Neural Networks: An Overview [Электронный ресурс]. – Режим доступа – URL: <https://arxiv.org/pdf/1404.7828.pdf> (Дата обращения 29.08.2018)
3. GMDH [Электронный ресурс]. – Режим доступа – URL: https://en.wikipedia.org/wiki/Group_method_of_data_handling (Дата обращения 10.09.2018)
4. Understanding Hinton's Capsule Networks [Электронный ресурс]. – Режим доступа – URL: <https://medium.com/ai%C2%B3-theory-practice-business/understanding-hintons-capsule-networks-part-i-intuition-b4b559d1159b> (Дата обращения 18.09.2018)

Оригинальность 98%