

УДК 159.9.016.4

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ В ОБРАЗОВАТЕЛЬНОЙ СФЕРЕ

Курбанов С.С., Мигалевич С.А.

Белорусский государственный университет информатики и радиоэлектроники, Минск, Республика Беларусь, seyitjan0306@gmail.com

Аннотация. В данной статье рассматривается применение нейронных сетей в образовательной сфере. Основные акценты делаются на использовании нейронных сетей для анализа данных, оптимизации процессов обучения и персонализации образовательных путей.

Ключевые слова. Нейронные сети, глубокое обучение, образовательная сфера, анализ данных, оптимизация обучения.

Нейронные сети давно считаются важной темой, на которую следует сосредоточить усилия в области образования, чтобы обеспечить быстрое и эффективное обучение. Кроме того, наличие обширных данных из разных источников подчеркивает потенциал нейронных сетей в качестве инструмента для анализа и выявления критических аспектов, планирования улучшений и корректировок, а в конечном итоге – улучшения процесса обучения. В этом контексте широко используются методы анализа и прогнозирования, которые позволяют принимать обоснованные решения политикам, управленцам и педагогам. Особенности рекуррентных нейронных сетей, особенно сетей долгой краткосрочной памяти, в анализе естественного языка позволяют использовать их для измерения сходства образовательных материалов. Массовые онлайн-курсы открытого доступа предоставляют обширное разнообразие данных о поведении онлайн-студентов. Анализ учебных траекторий дает понимание оптимизации процессов обучения, а также прогнозирования результатов и успеха. Еще одна активная область исследований – рекомендация персонализированных и адаптивных учебных путей на основе различных источников, включая отслеживание движений глаз. Таким образом, можно достичь перехода от пассивного обучения к активному. В статье представлены возможности применения нейронных сетей в образовательной сфере.

Извлечение полезных представлений из необработанных данных означает получение соответствующей информации в упрощенной форме и удаление избыточной информации и шума. Другими словами, создается упрощенная модель, которая объясняет наблюдаемые данные. Анализ полученного представления может выявить скрытые факторы, раскрыть ранее незамеченные связи между переменными и, в конечном счете, помочь получить полезное понимание исследуемого явления. Нахождение хорошего представления является ключевым во многих областях исследований, где данные поступают из разных источников и характеризуются высокой сложностью. Нейронные сети широко используются и успешно применяются для обучения представлений. Нейронные сети, как следует из их названия, вдохновлены структурой коры головного мозга человека. Они состоят из нескольких элементов, связанных между собой по направленной схеме (или без направления для машин Больцмана). Каждый элемент получает взве-

шенную сумму выходов связанных с ним элементов и применяет к этой сумме нелинейную функцию активации. Типичными функциями активации являются гиперболический тангенс и логистическая сигмоида. Модель нейронных вычислений обладает интересными теоретическими свойствами, и нейронные сети могут быть показаны как универсальные аппроксиматоры.

Нейронные сети изучают на основе набора обучающих примеров. Обычно обучение нейронной сети осуществляется с использованием стохастического градиентного спуска, при котором вычисляется градиент функции потерь (количественно оценивающей ошибку предсказания) относительно параметров сети с помощью алгоритма обратного распространения ошибки. Для обеспечения простоты архитектуры на сети накладываются ограничения на топологическую структуру: элементы располагаются в слоях, с соединениями только между элементами смежных слоев (рисунок 1). Промежуточные слои называются скрытыми слоями. Нейронные сети с по крайней мере двумя (или тремя, по мнению некоторых авторов) скрытыми слоями называются сетями глубокого обучения. Именно иерархическая структура обеспечивает глубоким сетям способность строить мощные представления. Последующие слои работают с промежуточными представлениями, построенными предыдущими слоями, так что внутренние представления находятся на более высоком уровне «абстракции».




Рисунок 1 – Нейронная сеть

Как и другие модели, нейронные сети работают в предположении, что примеры распределены независимо и одинаково в соответствии с (неизвестным) распределением. Таким образом, порядок появления примеров не имеет значения. Последовательные данные ставят перед нейронными сетями уникальные задачи, поскольку необходимо улавливать зависимости между данными, основанные на порядке. Несмо-

тря на то что сети могут быть спроектированы таким образом, чтобы справляться с последовательностями фиксированной длины, зависимости могут распространяться на интервалы переменной длины с возможными большими промежутками. Поэтому требуется изменение архитектуры. В то время как обычные нейронные сети имеют связи только между блоками в соседних слоях, рекуррентные нейронные сети (РНС) могут иметь циклы в своей графовой структуре. Таким образом, можно построить и поддерживать состояние, содержащее информацию обо всей наблюдаемой последовательности. При наблюдении новых элементов последовательности РНС обновляют свой текущий вектор состояния, чтобы отразить изменения. Возникает проблема, как выделить важные изменения и отбросить нерелевантные.

В теории рекуррентные нейронные сети (РНС) способны улавливать зависимости любой длины. Однако на практике очень длинные цепочки передачи градиента при разворачивании сети во времени приводят к исчезающим градиентам [1]. Необходим механизм для контроля накопления и передачи изменений состояния. Чтобы справиться с этой проблемой, были предложены сети с вентильными рекуррентными блоками, включая сети с долговременной памятью (LSTM) и сети с вентильными рекуррентными блоками (GRU).

Эти сети способны контролировать количество информации о прошлых входах, которая сохраняется на каждом этапе. Самозакливание регулируется дополнительными блоками - воротами, которые вводят способность забывать информацию о старом состоянии.




Рисунок 2 – Схема слоев LSTM

На рисунке 2 показана структура повторяющегося модуля в LSTM-сети, выделено состояние ячейки (верхняя часть), выход (нижняя часть). Слева направо: гейт забывания блок, блок входных ворот, блок ворот состояния кандидата и выходной ворот. Символ σ обозначает логистическую сигмоиду, которая разбивает свой вход на интервале $(0,1)$, где знак умножения обозначает произведение Хадамарда. В отличие от LSTM-сетей, в GRU забывание и обновление состояния ячейки делегируется одному гейту. GRU, будучи более простыми, показали улучшение вычислительной производительности по сравнению с LSTM. В остальном эти две модели конкурируют в широком спектре задач.

Строительство парадигм машинного обучения получило значительное влияние от психологических исследований обучения у людей и животных. Машинное обучение, в своем общем значении, автоматически извлекает знания из опыта, кристаллизованного в данных, и особенно привлекательно в

образовательной сфере. Это обусловлено двумя причинами. Во-первых, образовательная среда настолько сложна, что о данных распределении можно сделать мало предположений. Во-вторых, доступно огромное количество данных для исследования.

Машинное обучение в образовании находит применение в различных целях. Точное мониторинг состояния студентов во время обучения может поддерживать персонализированное, гибкое и адаптивное обучение, что прямо полезно для студентов и повышает уровень сохранения для образовательных учреждений. Моделирование студентов может быть основано на нескольких источниках данных, включая журналы взаимодействия, черты лица и движения глаз.

Применение моделей глубокого обучения к образовательным данным набрало популярность в 2015 году, когда была представлена система прогнозирования успеваемости студентов [3]. Интересным преимуществом такой системы является ее способность предоставлять предупреждения заранее, чтобы определить студентов, находящихся в риске, когда еще есть время для корректирующих мероприятий. Хотя применение моделей глубокого обучения и рекуррентных нейронных сетей в образовательном контексте является желательным, это сценарий создает некоторые уникальные проблемы, которые требуется решить. В частности, неоднородность и избыточность часто характеризуют данные в образовательном анализе, особенно при обнаружении скуки учащихся, и их следует правильно обрабатывать. Сложность состоит в разработке ручных характеристик, представляющих поведение студента [1]. Неспервиженные автокодировщики обучаются находить вложения данных, отображения в низкоразмерные пространства, которые улучшают производительность классификаторов и имеют потенциал показывать интересные идеи в данных, выявляя ранее незамеченные связи. Несмотря на то, что они полезны в качестве строительных блоков в модульных архитектурах сложных нейронных сетей, сами вложения могут быть анализированы и изучены отдельно, искать намеки на неожиданные ассоциации, которые проявляются в пространственной близости в упрощенном представлении данных.

В персонализированной и адаптивной среде обучения траектория обучения не фиксирована, а постоянно адаптируется, основываясь на индивидуальных характеристиках и состоянии знаний студента, чтобы помочь ему достичь поставленных целей в кратчайшие сроки. Персонализированные рекомендательные системы позволяют реализовать индивидуальную траекторию обучения для разных людей, опираясь на опыт других. Рекомендательные системы должны быть оптимизированы с точки зрения разнообразия, новизны и интенсивности взаимодействия. В ранних рекомендательных системах фильтрация на основе контента давала рекомендации учащемуся на основе того, что в прошлом предпочитали учащиеся с похожими вкусами. Чтобы объединить учащихся со схожими предпочтениями в системе совместного обучения,



естественно обратиться к алгоритмам кластеризации, основанным на различных метриках сходства.

Для представления связей между учащимися, элементами и тегами можно использовать трехсторонний граф, который изначально был статическим и основывался на исторической информации. Недавно был предложен подход, при котором трехсторонний граф взаимодействия, моделирующий троичные отношения между учащимися, поведением взаимодействия и учебным контентом, становится динамичным. Таким образом, модные темы, привлекающие большое внимание, могут легко распространяться среди учащихся. Веса в динамическом трехстороннем графе взаимодействия инициализируются, а затем с помощью сверточной нейронной сети, управляемой вниманием, происходит обновление весов.

На онлайн-платформах подготавливается и загружается большое количество упражнений для оценки степени освоения учащимися определенной темы. Возможность находить похожие упражнения, то есть упражнения с общей целью, может значительно обогатить процесс обучения. Автоматическая группировка упражнений на основе их сходства является нетривиальной задачей, поскольку упражнения обычно содержат гетерогенные данные, такие как текст и изображения, и сходство на уровне слов или понятий может привести к ошибочной группировке. В данной задаче были объединены сверточная нейронная сеть (CNN) и LSTM с механизмом внимания (Attention). CNN обрабатывает изображения, слой вложений создает представления для понятий, а LSTM с механизмом внимания создает конечное семантическое представление.

Такое сочетание компонентов свидетельствует о наметившейся тенденции в исследованиях. В будущем подсети будут либо продолжать соединяться модульным образом, каждый компонент будет заниматься теми частями входных данных, которые он обрабатывает лучше всего, либо мы станем свидетелями разработки новой гибридной архитектуры, специально разработанной для того, чтобы она могла обрабатывать все данные.

Открытие скрытой структуры и закономерностей в данных, полученных из систем онлайн-обучения, имеет ценность в образовании, поскольку позволяет получить более глубокое понимание и разработать высоко гибкое, адаптивное и персонализированное предложение. Глубокие нейронные сети и их способность распутывать ранее неожиданные связи являются очень перспективными инструментами в этой работе.

Однако выбор наиболее подходящей архитектуры глубокой сети для конкретной задачи по-прежнему яв-

ляется проблемой, требующей навыков и экспертизы. Основные архитектуры имеют свои преимущества и недостатки в терминах возможностей и производительности, и требуется тщательное взвешивание при выборе. После принятия решения следующим шагом является определение подходящих архитектурных гиперпараметров, что также требует проведения обширных экспериментов для определения уровня индуктивного смещения, который улучшает способность обобщения.

Доступность публичных наборов данных для экспериментов с новыми идеями и оценки их эффективности – критический фактор для исследований в этой области. Имеющиеся в настоящее время наборы данных по образованию, например, наборы данных Edx или WorldUC, являются отправной точкой, но не могут полностью покрыть требования для некоторых экспериментов. Поэтому расширение общедоступных данных будет приветствоваться. Перспективы будущих исследований широки и благоприятны. Что касается усовершенствования архитектуры РНС, было предпринято несколько попыток, среди которых наиболее интересными представляются аттениционные интерфейсы, когда РНС может фокусироваться, в зависимости от контекста, на значимых частях своего входа, которые имеют отношение к предсказанию следующей цели; специальный модуль регулирует это решение. Например, RNN может управлять выходом другого RNN. Все предложенные усовершенствования, по-видимому, могут способствовать ослаблению топологических ограничений при компоновке сети – идея, которая уже начала давать интересные результаты при использовании пропущенных соединений в остаточных сетях и гиперсетях.

Литература

1. Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2), 157–166.
2. Bosch, N., & Paquette, L. (2017). Unsupervised deep autoencoders for feature extraction with educational data. Paper presented at the Deep Learning with Educational Data Workshop at the 10th International Conference on Educational Data Mining, Urbana, IL, USA.
3. Guo, B., Zhang, R., Xu, G., Shi, C., & Yang, L. (2015). Predicting students performance in educational data mining. In 2015 International Symposium on Educational Technology (ISET) (pp. 125–128), IEEE.

DEVELOPMENT OF SOFTWARE FOR VIDEO SURVEILLANCE SYSTEMS DESIGN AND ANALYSIS

S.S. Kurbanov, S.A. Migalevich

Belarusian State University of Informatics and Radioelectronics, Minsk, Belarus, seyitjan0306@gmail.com

Abstract. The article discusses the application of neural networks in the field of education. The main emphasis is placed on the use of neural networks for data analysis, optimizing learning processes, and personalizing educational paths.

Keywords. Neural networks, deep learning, the education sector, data analysis, learning optimization.