

Препятствие	Дополнительные потери (дБ)	Эффективное расстояние*
Открытое пространство	0	100%
Окно без тонировки (отсутствует металлизированное покрытие)	3	70%
Окно с тонировкой (металлизированное покрытие)	5-8	50%
Деревянная стена	10	30%
Межкомнатная стена (15,2 см)	15-20	15%
Несущая стена (30,5 см)	20-25	10%
Бетонный пол/потолок	15-25	10-15%
Монолитное железобетонное перекрытие	20-25	10%

Рисунок 4 – Коэффициенты потери мощности от препятствий

ЛИТЕРАТУРА

1. Mikrotik Documentaion [Электронный ресурс] - Режим доступа: https://wiki.mikrotik.com/wiki/Manual:IP/DHCP_Server- Дата доступа: 11.12.2023.
2. Mikrotik Documentaion [Электронный ресурс] - Режим доступа: <https://wiki.mikrotik.com/wiki/Manual:IP/DNS>- Дата доступа: 11.12.2023.

РАЗРАБОТКА И ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ КЛАССИФИКАЦИИ ФЛЮОРОГРАФИЙ ОРГАНОВ ГРУДНОЙ КЛЕТКИ НА НАЛИЧИЕ ПНЕВМОНИИ DEVELOPMENT AND TRAINING OF A NEURAL NETWORK FOR CLASSIFYING FLUOROGRAPHY OF THE CHEST ORGANS FOR THE PRESENCE OF PNEUMONIA

С. С. Егоров, И. В. Лефанова
S. Egorov, I. Lefanova

Учреждение образования «Международный государственный экологический институт имени А. Д. Сахарова» Белорусского государственного университета, МГЭИ им. А. Д. Сахарова БГУ, г. Минск, Республика Беларусь
egorov@iseu.by

International Sakharov Environmental Institute of Belarusian State University, ISEI BSU, Minsk, the Republic of Belarus

В работе представлены результаты проектирования, разработки и обучения нейронной сети для классификации медицинских изображений на примере флюорографии органов грудной клетки на наличие пневмонии.

The paper presents the results of designing, developing and training a neural network for classifying medical images using the example of chest fluorography for the presence of pneumonia.

Ключевые слова: нейронные сети, сверточные сети, полносвязные сети, алгоритмы градиентного спуска.

Keywords: neural networks, convolutional networks, fully connected networks, gradient descent algorithms.

<https://doi.org/10.46646/SAKH-2024-2-247-250>

Нейронные сети в последние несколько лет набирают стремительную популярность и проникают в различные области деятельности человека, и медицина не является тому исключением. Данная работа имеет целью исследование возможности применения нейронных сетей в медицине для классификации изображений на предмет наличия или отсутствия патологий.

Нейронные сети – это математические модели особого вида, вдохновлённые биологическими нервными системами, нацеленные на моделирование их сложного поведения и решения задач не имеющих ясного алгоритма путём машинного обучения, такие как распознавание объектов на изображениях, генерация «осмысленного» текста, поддержка принятия решений и др. Нейронная сеть представляет собой систему соединённых и взаимодействующих между собой простых объектов «нейронов», способных получать, обрабатывать и передавать дальше другим нейронам сигналы, представленные действительными числами. Несмотря на кажущуюся простоту, большое количество таких нейронов может выполнять довольно сложные задачи. Например, входные нейроны могут быть пикселями изображения, а выходной нейрон – уверенность нейронной сети в том, что на фото изображён какой-то объект, процесс или явление.

Развитие и применение искусственного интеллекта и машинного обучения с каждым годом становится все более активным, и они представляют огромный потенциал для различных областей медицины. Так, например, можно выделить следующие потенциальные применения нейронных сетей:

– **Диагностика заболеваний.** Нейронные сети могут быть обучены распознавать закономерности и связи в медицинских данных, что делает их полезными в диагностике различных заболеваний. Они могут анализировать медицинские изображения, такие как снимки МРТ, рентгеновские снимки или гистологические срезы, для выявления признаков патологий, улучшения точности диагностики и автоматической интерпретации результатов.

– **Персонализированное лечение.** Нейронные сети могут использоваться для разработки моделей, которые помогают определить наиболее эффективное лечение для пациентов. Они могут быть использованы для анализа данных о пациенте, таких как генетическая информация, медицинская история и результаты лабораторных тестов, и предложения индивидуальных рекомендаций по выбору лекарств, дозировке и терапии.

– **Анализ медицинских текстов.** Нейронные сети могут использоваться для анализа и обработки медицинских текстов, таких как медицинские записи, научные статьи и отчеты о пациентах. Они могут автоматизировать процесс извлечения информации из больших объемов текстовых данных и предоставить врачам доступ к актуальной информации и научным исследованиям.

– **Прогнозирование эпидемий и общественного здоровья.** Нейронные сети могут использоваться для анализа данных о заболеваемости, распространении инфекций и других факторов, влияющих на общественное здоровье. Они способны прогнозировать распространение эпидемий, помогать в планировании ресурсов и разработке эффективных мер по предотвращению заболеваний.

В данной работе для задачи диагностики выбором типа нейронной сети является полносвязная нейронная сеть прямого распространения. Выбран именно такой тип на основании того, что это один из двух основных типов нейронных сетей, используемых на практике для классификации изображений. Другим типом являются свёрточные нейронные сети, однако выбор пал в пользу полносвязных сетей ввиду того, что они значительно проще в реализации и обучении, и в то же время способны демонстрировать вполне приемлемые результаты по классификации изображений.

Итоговая цель стоит разработать программное обеспечение, способное обучать и применять полносвязные нейронные сети для классификации флюорографий органов грудной клетки в 2 класса – с наличием и с отсутствием пневмонии.

Таким образом, объектом исследования являются полносвязные нейронные сети, предметом исследования является возможность использовать полносвязную нейронную сеть как бинарный классификатор результатов флюорографий. Успехом будет считаться обучение модели нейронной сети-классификатора с точностью классификации 80% или более и минимизацией количества ложно-негативных классификаций по результатам оценки работы модели на валидационной выборке.

Следует также отметить, что целью не является разработка «безупречной» или даже «оптимальной» нейронной сети. Вместо этого, цель подразумевает создание нейронной сети и обучения её до заданной точности как проверку осуществимости концепции применения нейронных сетей для классификации конкретного вида изображений для их применения в медицине.

В рамках данной работы рассмотрена полносвязная нейронная сеть со следующей топологией: входной слой имеет 256х256 нейронов, по по одному для каждого пикселя, 2 скрытых слоя размерами 40 нейронов и 10к нейронов, и выходной слой из 2 нейронов.

Слой	Кол-во нейронов	Функция активации
Входной	$256 * 256 = 65536$	Не применяется
1-ый скрытый	40	Leaky ReLU
2-ой скрытый	10 000	Leaky ReLU
Выходной	2	Сигмоида с параметром 1

Рисунок 1 – Исходная топология нейронной сети

Итого, при данной топологии нейронная сеть имеет примерно 3 миллиона весов. Размер обучающей выборки составляет 7600 изображений размером 256*256 монохромных пикселей, итого ≈ 500 миллионов входных значений. Таким образом, соотношение количества параметров к количеству входных данных составляет 1/166. Распространённой практикой является держать соотношение количества параметров сети к количеству входных данных на уровне 1/1000 – 1/100.

Слой	Кол-во весов	Кол-во смещений	Итого параметров
1-ый скрытый	$65536 * 40 = 2621440$	40	2621480
2-ой скрытый	$40 * 10\,000 = 400\,000$	10000	410000
Выходной	$10\,000 * 2 = 20\,000$	2	20002
Итого	3 041 440	10042	3 051 482

Рисунок 2 – Исходная топология нейронной сети

Стоит отметить, что у обычного алгоритма градиентного спуска применительно к нейронным сетям есть свои недостатки. Например, его скорость работы. Дело в том, что вычисление градиента для нейронной сети является достаточно трудоёмкой задачей. Так, например, с заданной обучающей выборкой в 7600 изображений размером 256x256, на процессоре Intel Core i3-12100F одна эпоха обучения проходит примерно за 18 секунд. Существуют вариации алгоритма, позволяющие ускорить обучение, добиться лучшей сходимости, и т. д. Наиболее распространённые вариации алгоритма градиентного спуска включают:

- Пакетный градиентный спуск (от англ. batch gradient descend). Идея заключается в том, чтобы при вычислении градиента использовать не всю обучающую выборку, а только её ограниченное подмножество, выбираемое случайным образом для каждой эпохи. Данный алгоритм позволяет получить регулируемый компромисс между скоростью вычисления градиента и точностью результата. Данный алгоритм был изначально использован в рамках данной курсовой работы для обучения новых моделей нейронной сети. Он действительно значительно ускоряет обучение, однако недостаток заключается в том, что после конкретного момента обучение перестаёт давать результаты и алгоритм «сходится» на некоторой точке в пространстве параметров нейронной сети, после которой всё ещё возможно улучшение точности при использовании обычного градиентного спуска.

- Стохастический градиентный спуск (от англ. stochastic gradient descend). Идея заключается в том, чтобы взять пакетный градиентный спуск и довести его до экстремального случая: использовать лишь одну входную пару данных из обучающей выборки для каждой эпохи. Данный алгоритм может являться крайне нестабильным, однако в то же время может очень сильно ускорить обучение на начальных стадиях обучения.

Набор данных, используемый для обучения, является компиляцией наборов данных, найденных в открытом доступе на Kaggle и содержал изображения в формате jpeg, которые в дальнейшем были преобразованы в формат bmp для упрощения работы с ними.

Обучение длилось несколькими сессиями суммарно несколько суток. В результате обучения модели нейронной сети в течение данного периода времени удалось добиться точности классификации 82.75% по оценке на валидационной выборке.

```

Microsoft Visual Studio Debug Console

Session seed is 3
Trying to load existing model... success
Enter online classification mode? (y/n):
loading training dataset... size = 7600, dt = 1955 ms
loading test dataset... size = 400, dt = 102 ms
evaluating initial cost... cost = 0.024043513
AC = 82.8%, TP ~ 49.8%, TN ~ 33%, FP ~ 17%, FN ~ 0.25%
Training is running on 8 threads
Using regular gradient descend
Learning rate is 0.0020093874
Press Ctrl-C to finish
Press Ctrl-Break to cancel
Settings mode:
rate = 0.0020093874 (decay_n = 5) (q = up, a = down)
continue_on_increased_cost = true (w = change)
ESC = continue
~ = continue for one iteration
Iteration 0: 17978 ms, cost -> 0.024042463 (d = 1.0505319e-06), AC = 82.75%,
Iteration 1: 18146 ms, cost -> 0.024041506 (d = 9.573996e-07), AC = 82.75%,
Iteration 2: 18260 ms, cost -> 0.024040496 (d = 1.0095537e-06), AC = 82.75%,
Iteration 3: 17994 ms, cost -> 0.024039444 (d = 1.0523945e-06), AC = 82.75%,
Iteration 4: 18016 ms, cost -> 0.024038384 (d = 1.0598451e-06), AC = 82.75%,
Save complete, stopping by user request

```

Итоговое распределение результатов классификации выглядит следующим образом: 49.75% истинно-положительных классификаций, 33% истинно-негативных классификаций, 17% ложно-положительных классификаций, 0.25% ложно-негативных классификаций.

Отсюда легко вычислить стандартные характеристики классификатора следующим образом: точность 82.75%, чувствительность 99.5%, специфичность 66%, прогностическая ценность положительного результата 74.5%, прогностическая ценность отрицательного результата 99.25%. Другими словами, такая модель будет периодически (примерно в одном из четырёх случаев) выдавать заключение «пневмония», когда пневмонии на самом деле нет, но очень редко (7.5 случаев на 1000) выдавать заключение «пневмонии нет», когда она на самом деле есть, то есть обнаруживает пневмонию, при её наличии, такая модель достаточно хорошо, хоть периодически и даёт ложные срабатывания.

Стоит также упомянуть, что 0.25% ложно-негативных срабатываний это очень приблизительная цифра, полученная следующим образом: валидационная выборка содержит 400 изображений, из которых для одного изображения результат классификации был ложно-негативный, итого $1/400 = 0.25\%$. Для уточнения доли ложно-негативных классификаций, в идеале, необходим больший набор данных.

По мере продолжения процесса обучения, улучшение точности шло всё медленнее и медленнее, в связи с чем после достижения отметки точности слегка больше 80% было принято решение остановить обучение. Точное итоговое количество эпох обучение неизвестно, приблизительная оценка составляет 10 000 эпох.

Данная реализация нейронной сети ни в коем случае не претендует на звание «оптимальной» или «эталонной». Напротив, она служит лишь доказательством концепции. Так, среди слабых сторон можно выделить:

1. **Слишком простой подбор гиперпараметров.** В рамках данной курсовой работы топологий нейронной сети была выбрана исходя из некоторых существующих практик подбора топологии. Не ставились эксперименты по определению влияния гиперпараметров на процесс обучения.

2. **Полносвязность.** Распространённой практикой является также использование свёрточных нейронных сетей для классификации изображений. Такой тип нейронных сетей более сложен, однако как правило даёт лучшие результаты по сравнению с полносвязными нейронными сетями.

3. **Обучение с использованием центрального процессора.** Использование графических процессоров в обучении нейронных сетей является распространённой практикой в обучении нейронных сетей, позволяющих ускорить обучение за пределы возможности ускорения на центральных процессорах.

4. **Отсутствие использования аппаратных средств векторизации вычислений.** Современные процессоры поддерживают концепцию SIMD (single instruction, multiple data), реализованную в виде специальных наборов инструкций (семейства SSE и AVX для процессоров на архитектуре x86), позволяющих одной инструкции более эффективно использовать АЛУ процессора, выполняя несколько однотипных вычислений одновременно. И хотя современные компиляторы иногда способны «векторизовать» код, у программистов никогда нет гарантий этого, поэтому данное направление оптимизации требует внимания и экспериментов.

5. **Решение относительно простой задачи.** Пневмония, как правило, достаточно отчётливо видна на снимках органов грудной клетки. Хотя такая нейронная сеть и может неплохо обнаруживать пневмонию и даже потенциально помогать врачам в спорных случаях, всё же хорошим направлением для улучшения будет разработать и обучить модель, занимающуюся мультиклассовой классификацией, отличающую, например, пневмонию от рака.

Таким образом, в ходе выполнения работы были продемонстрированы способы описания, создания и обучения простых типов полносвязных нейронных сетей, применительно к классификации медицинских изображений. Итоговая модель имеет точность выше 80% и очень высокую (примерно 99%) прогностическую ценность отрицательного результата. Это говорит о том, что нейронные сети действительно могут являться хорошим инструментом анализа медицинских данных, на основании которых можно делать предположения о наличии или отсутствии конкретного вида патологий у объектов исследования. Другими словами, нейронные сети имеют большой потенциал и до сих пор являются объектом разносторонних исследований, и могут быть применены в медицине как для анализа медицинских изображений, так потенциально и каких-либо других медико-биологических данных.