

Новые подходы к развитию технологий искусственного интеллекта на основе метода ближайшего соседа

И.И. Приезжев^{1,2}, Д.А. Данько^{1,2}, А.В. Шубин^{1,2}

¹РГУ нефти и газа (НИУ) имени И.М. Губкина, Москва, Россия

²ООО «Лаборатория Приезжева», Москва, Россия

Аннотация

Современные нейросетевые технологии, включая большие языковые модели, достигли выдающихся успехов в различных прикладных задачах искусственного интеллекта, однако сталкиваются с рядом фундаментальных ограничений. Среди них – эффект «галлюцинаций», высокая вычислительная сложность обучения и вывода, дорогостоящее дообучение и проблемы катастрофического забывания. Эти ограничения серьезно препятствуют применению нейронных сетей в критически важных областях, таких как медицина, управление производственными процессами и научные исследования. В настоящей статье предлагается альтернативный подход на основе метода ближайшего соседа с построением иерархических кластерных структур. Использование алгоритма k-ближайших соседей позволяет существенно снизить или полностью исключить эффект «галлюцинаций», обеспечивая при этом простоту расширения и дообучения модели без необходимости переобучения всей сети. Для преодоления высокой вычислительной нагрузки метода k-ближайших соседей в работе предложено использовать древовидные структуры данных на основе самоорганизующихся карт Кохонена, позволяющие значительно ускорить поиск ближайших соседей. Проведенные тесты на задачах распознавания рукописных цифр и простого перевода субтитров подтвердили эффективность предложенного подхода. При незначительном снижении точности удалось сократить время поиска ближайших соседей в сотни раз по сравнению с методом полного перебора. Предлагаемый метод отличается прозрачностью и интерпретируемостью решений, близостью к механизмам человеческого мышления и имеет потенциал для широкого использования в задачах, требующих высокой надежности и объяснимости результатов.

Ключевые слова: машинное обучение, иерархические нейронные сети, k-ближайших соседей, самоорганизующиеся карты Кохонена

1 Введение

Современные системы искусственного интеллекта, в частности большие языковые модели (*англ.* Large Language Models или LLM) на основе нейронных сетей, демонстрируют впечатляющие возможности. Например, крупные языковые модели (GPT, PaLM, LLaMA и др.) способны генерировать связный текст, переводить, отвечать на вопросы и решать сложные задачи [7]. Вместе с тем уже выявлены серьезные концептуальные ограничения этих подходов: эффект «галлюцинаций» (*англ.* hallucination), сложность обучения, дорогостоящее дообучение и другие. Преодолеть эти ограничения весьма сложно без пересмотра фундаментальных концепций построения систем искусственного интеллекта.

В настоящей статье мы анализируем причины основных недостатков классических нейросетевых технологий и предлагаем альтернативный подход для дальнейшего развития алгоритмов и архитектур искусственного интеллекта.

В качестве базового механизма нового подхода рассматривается алгоритм *k*-ближайших соседей (*англ.* *k*-Nearest Neighbours или *k*-NN) [13], основанный на прямом сравнении тестируемого объекта со всеми элементами обучающего набора. Этот метод опирается на принцип аналогий, что обеспечивает прозрачность логики принятия решений и интерпретацию результатов. Среди ключевых преимуществ алгоритма *k*-NN – отсутствие этапа обучения, отсутствие галлюцинаций и простота расширения обучающего набора путем добавления новых объектов [10]. Вместе с тем данный подход обладает существенными недостатками: значительной вычислительной нагрузкой при переборе обучающего множества и необходимостью хранения полного набора данных, объем которого может быть очень велик [4].

Для ускорения поиска ближайших соседей предлагается предварительно обобщать обучающий набор, формируя древовидные иерархические структуры, в узлах которых хранятся обобщенные представления схожих информационных элементов. Метод ускоренного поиска ближайших соседей на основе иерархических сетей был ранее предложен и опробован нами в работе [1] для решения прогнозных задач интерпретации сейсмических данных.

Цель настоящей работы – углубленное исследование данного подхода и адаптация его для решения более широкого круга задач в области искусственного интеллекта.

2 Недостатки нейросетевых технологий

Нейросетевые технологии обладают рядом существенных ограничений, сдерживающих их дальнейшее развитие:

- **Эффект «галлюцинаций».** Этим термином описывается ситуация, когда модель выдает правдоподобные, но ложные или бессмысленные утверждения.

Обусловлен этот эффект статистическим предсказанием токенов без прямой привязки к исходным примерам. При отсутствии в обучении близких по контексту или форме данных модель интерполирует или экстраполирует информацию, что и приводит к появлению неточных или вовсе фиктивных утверждений [22]. Этот феномен присущ как крупным LLM, так и небольшим генеративным сетям, что ограничивает их применение в сценариях, где требуется гарантированная достоверность получаемых результатов.

В критически важной сфере здравоохранения даже незначительная ошибка в диагностике способна вызвать тяжелые последствия для пациентов, а в автоматизированных системах управления промышленными процессами недоверие к прогнозам нейросети затрудняет внедрение подобных технологий в производство [36]. С ростом числа срабатываний «ложных тревог» повышается риск отказа от решений, связанных с искусственным интеллектом (ИИ), что снижает общую эффективность и надежность цифровых систем.

- **Сложность обучения.** Тренировка современных моделей проводится на огромных по своим объемам наборах данных и требует оптимизации сотен миллионов или миллиардов параметров. Согласно законам масштабирования, объем используемой информации и затраты вычислительных ресурсов растут по степенному закону с увеличением количества параметров и размера текстов [24]. При этом углеродный след одного цикла обучения крупных моделей оценивается в десятки тонн CO₂-эквивалента, что ставит вопрос об экологической устойчивости развития нейросетевых технологий [34].

Не менее существенной является проблема высокой вычислительной нагрузки и объема оперативной памяти при выполнении вывода (*англ.* inference) - этапе применения уже обученной модели для получения предсказаний. Запуск мегамоделей в реальном времени требует серверных архитектур с большим количеством GPU (*англ.* Graphics Processing Unit) или TPU (*англ.* Tensor Processing Unit) и значительным объемом видеопамати, что ограничивает применение нейросетей в мобильных и встроенных системах без применения компрессии или дистилляции знаний (*англ.* knowledge distillation) модели [38].

- **Дорогостоящее дообучение.** Для адаптации к новым задачам и дообучения (*англ.* fine-tuning) активно используются методы параметрически эффективной адаптации, такие как Low-Rank Adapters (LoRA) и адаптеры-слои. Они позволяют обновлять лишь малую часть весов и снижать потребление ресурсов, однако при этом сохраняется зависимость от изначального объема обучающего массива и сложности модели [20]. Полное исключение ресурсоемкой переобучения все еще остается нерешенной задачей.
- **Катастрофическое забывание** (*англ.* catastrophic forgetting) - явление, при котором нейросети быстро теряют ранее приобретенные знания при дообучении на новых данных. Это ограничивает возможности непрерывного обучения в динамически меняющихся средах. В ряде работ предложены методы регуляризации и памяти с ограниченным ресурсом, но универсального решения проблемы до сих пор нет [26].
- **Хрупкость нейросетей** проявляется в уязвимости к «враждебным» атакам (*англ.* adversarial attacks): небольшие, зачастую незаметные человеку, возмущения входных данных могут привести к радикальной ошибке в выводе модели. Это ставит под сомнение применение сетей в системах безопасности и автономного управления [35].
- Важной проблемой является **калибровка результатов моделей**: современные нейросети склонны быть чрезмерно уверенными в своих предсказаниях, что затрудняет оценку степени неопределенности и риска принятия решения на их основе [16]. Отсутствие корректной калибровки приводит к недооценке ошибок и возможному провалу систем, критичных к неверным прогнозам.

- **Этика и справедливость нейросетевых решений** зависят от качества обучающих данных. Смещенность *англ.* и предвзятость в датасете, например, приводят к дискриминации по социальным или половым признакам, что подтверждается исследованиями на примерах систем распознавания лиц и классификации текста [8]. Борьба с такими артефактами требует тщательной очистки данных и внедрения алгоритмов определения смещенности.
- Наконец, **«черный ящик»** внутренних механизмов нейросетей остается одной из основных преград для их широкого применения. Отсутствие прозрачности и трудности интерпретации работы модели стимулируют развитие интерпретируемых ИИ (*англ.* Explainable AI или ХАИ) - направление исследований, направленное на разработку методов и инструментов, обеспечивающих прозрачность и объяснимость решений сложных моделей [15]. Несмотря на значительный прогресс, существующие методы ХАИ часто оказываются либо слишком упрощенными для сложных архитектур, либо ухудшают точность модели, что подчеркивает необходимость дальнейших исследований в области баланса между объяснимостью и эффективностью.

Таким образом, несмотря на выдающиеся достижения, нейросетевые технологии сталкиваются с рядом фундаментальных ограничений: от технических и экологических до этических и методологических. Решение этих проблем требует междисциплинарного подхода, совмещения усилий исследований в области алгоритмов, аппаратного обеспечения и нормативного регулирования.

3 Метод ближайшего соседа

Метод k-NN – классический непараметрический алгоритм машинного обучения, относящийся к «ленивым» (*англ.* lazy) методам, так как не требует явной фазы обучения [10]. Его работа сводится к тому, что для каждого нового образца вычисляются расстояния до всех точек обучающего множества, после чего прогноз строится на основе меток (в задаче классификации) или значений отклика (в регрессии) k наиболее близких соседей.

Этот метод очень стабильный и имеет множество *преимуществ*:

- **Отсутствие «традиционного» этапа обучения.** В методе k-NN нет фазы подбора или оптимизации внутренних весов модели: все точки сразу сохраняются в базе, а «интеллект» заключается в динамическом поиске ближайших соседей при каждом прогнозе. Появление новых примеров не требует повторного обучения - достаточно добавить их в хранилище, и алгоритм сразу начнет учитывать обновленный набор данных.
- **Обнаружение аномалий** (*англ.* outlier/anomaly detection). Устанавливая порог расстояния до ближайшего соседа, можно выявлять образцы, не похожие ни на один из примеров в наборе данных. Такой подход широко применяется в задачах выявления новизны и аномалий [9].
- **Интуитивная объяснимость.** Прогноз моделируется напрямую через явно заданные аналогии: пользователь может привести примеры соседей, обосновывающие выбор алгоритма. Это упрощает интерпретацию и доверие к результатам [18].

- **Гибкость метрики.** В зависимости от природы признаков можно использовать Евклидову, Манхэттенскую, косинусную, Минковского и другие метрики, адаптируя алгоритм к конкретным данным.
- **Асимптотическая оптимальность.** При объеме обучающей выборки $n \rightarrow \infty$ и подходящем выборе k ошибка k-NN классификатора стремится к ошибке Байеса, а для $k = 1$ верхняя граница ошибки не превышает двойной ошибки Байеса.

Несмотря на явные преимущества метода, k-NN обладает рядом существенных *недостатков*:

- **Вычислительная сложность.** Наивная (*англ.* «naïve implementation») реализация метода требует $O(n \cdot d)$ операций на каждый запрос (где n – число образцов, d – размерность признаков), что при больших объемах данных и высокой размерности превращается в «бутылочное горлышко».
- **Потребность в хранении всего набора данных.** Для работы алгоритма все обучающие образцы должны быть доступны в памяти или на диске, что ограничивает масштаб и скорость обработки.
- **Чувствительность к размерности.** Так называемое «проклятие размерности» (*англ.* «curse of dimensionality»), заключающееся в том, что расстояния в высоких размерностях становятся неинформативными, ухудшая качество поиска близких точек. Для компенсации этого недостатка требуется предварительная обработка (отбор признаков, понижение размерности) [18].
- **Необходимость выбора параметра k и метрики.** Хотя у k-NN отсутствует обучение весов, у него есть ключевые гиперпараметры: число соседей (k) и способ измерения расстояния. Если (k) слишком мало, алгоритм становится избыточно чувствительным к отдельным «шумовым» примерам (аналог переобучения). Если (k) слишком велико, решения получаются чрезмерно усредненными и теряют детали структуры (аналог сильного занижения). Выбор оптимального k , а также наиболее подходящей метрики, обычно выполняют с помощью кросс-валидации [30].

4 Иерархические структуры обобщенных данных

При сравнении нейронной сети для задачи классификации с простым перебором обучающего массива для поиска ближайшего соседа следует отметить, что оба подхода могут давать одинаковый результат. Однако нейросетевое решение работает значительно быстрее: обучающий массив фактически «вшивается» в сеть в виде набора весовых коэффициентов. Иными словами, нейросеть представляет собой параллельный механизм, обеспечивающий ускоренный поиск, аналогичный результату полного перебора. Главная же цена такого ускорения - потеря прямой трассируемости результата до конкретных обучающих примеров: ответ становится «обобщенным» и не указывает на отдельные образцы данных.

Для ускорения поиска ближайшего соседа разработаны различные методы, например алгоритм «иерархического навигируемого графа малого мира» (*англ.* Hierarchical Navigable Small World или

HNSW) [30]. Основная суть данного метода заключается в построении нескольких уровней «малого мира» - рандомизированных графов, каждый из которых обеспечивает жадный переход к ближайшим узлам вплоть до базового слоя. Это позволяет достичь сублинейной, практически логарифмической, сложности в задачах с высокой размерностью. Мы используем подобный подход на основе построения иерархического поискового дерева решений [1]. Идея заключается в структурном обобщении обучающей выборки путем построения многоуровневой поисковой сети, где объекты группируются по степени их сходства. Подобные приемы широко используются в практических задачах. Так, при поиске книги в большой библиотеке нет нужды просматривать весь фонд: достаточно обратиться к каталогу, где нужная книга находится в соответствующем разделе или подразделе - классический пример иерархической поисковой структуры.

Реализация предлагаемого подхода начинается с первого уровня обобщения, где кластеризация обучающих объектов разбивает выборку на несколько узлов (кластеров) на основе меры сходства. Затем каждый кластер последовательно разделяется на дочерние узлы до достижения заданной глубины дерева или минимального размера кластера. Узлы, содержащие один или небольшое число объектов, рассматриваются как листья поискового дерева.

Если в одном листе объединены объекты с разными метками или существенно различающимися прогнозными параметрами, это свидетельствует о недостаточности описания признаков или некорректности выбранной меры сходства. Напротив, объекты с одинаковыми метками или близкими прогнозными значениями в одном листе можно заменить единым «обобщенным» объектом, что позволяет существенно сократить объем обучающей выборки.

Процедуру построения иерархического поискового дерева можно рассматривать как этап обучения, а итоговую структуру - как деревообразную нейросеть расширяющего типа. На вход такой сети подается описание тестового объекта в виде вектора. На каждом уровне иерархии выбирается наиболее близкий узел, после чего поиск продолжается лишь по его дочерним узлам до достижения листа. Окончательный перебор объектов в листе позволяет найти ближайшего соседа (или несколько соседей) из обучающего множества.

Каждый узел в этой сети аналогичен «нейрону» в классической архитектуре: уровень узла определяет степень обобщения. В терминах библиотечного каталога первый уровень соответствует «залам» по обобщенным темам (научная литература, художественная литература и т. п.), следующий - стеллажам с книгами по конкретным дисциплинам, а последующие - подразделам, уточняющим тематику.

Путь поиска в иерархической нейросети представляет собой цепочку узлов, максимально приближенных к тестовому объекту (рис. 1). Это кардинально отличает данный механизм от стандартной нейронной сети, где входной сигнал распространяется по всем нейронам.

Затем значения нейрона «победителя» корректируются по правилу:

$$W_j(t+1) = W_j(t) + \alpha(t)h_{\sigma(t)}(d(j, j^*)) [S_i - W_j(t)] \quad (4)$$

где

$\alpha(t)$ – скорость обучения, убывающая с течением итераций;

$d(j, j^*) = |j - j^*|$ – расстояние в индексе узлов вдоль 1D-карты;

$h_{\sigma(t)}$ – функция соседства; часто применяются гауссиан:

$$h_{\sigma}(d) = \exp\left(-\frac{d^2}{2\sigma^2}\right) \quad (5)$$

или «мексиканскую шляпу»:

$$h_{\sigma}(d) = \left(1 - \frac{d^2}{\sigma^2}\right) \exp\left(-\frac{d^2}{2\sigma^2}\right) \quad (6)$$

которые обеспечивают коррекцию ближайших соседей по убывающей функции от расстояния [27].

5.3 Расширение на SOM 2D/3D

Для варианта кластеризации SOM 2D и SOM 3D узлы организованы в карту размера $k \times k$ или куба $k \times k \times k$. Тогда индекс узла становится вектором (j_1, j_2) или (j_1, j_2, j_3) и вычисляется как евклидово (или манхэттенное) расстояние на решетке. Обновление весов происходит по тому же правилу, но с учетом многомерного соседства по всем осям. В этом случае корректируются значения нейронов, близких по всем индексам к нейрону «победителю».

5.4 Сокращение размерности и прототипирование

После обучения каждый входной вектор S_i может быть однозначно отнесен к узлу-«нейрону» j^* . Полученные индексы можно интерпретировать как новые переменные, и алгоритм кластеризации SOM 1D/2D/3D может рассматриваться не только как метод группирования похожих объектов, но и как метод сокращения признакового пространства. Таким образом, мы осуществляем проекцию из n -мерного пространства признаков в новое пространство размером k (1D), $k \times k$ (2D) или $k \times k \times k$ (3D).

Переход к более высоким размерностям (2D, 3D) улучшает сохранение топологической структуры данных и снижает ошибку квантизации. При необходимости можно обобщить метод на m D-карты, однако с ростом размерности возрастают вычислительные затраты и сложность выбора соседской функции.

6 Тестирование алгоритма

6.1 Распознавание рукописного текста

Для проверки работоспособности и производительности предложенного метода была реализована задача распознавания цифр на наборе MNIST (Modified National Institute of Standards and Technology). В датасете MNIST содержится 60 000 изображений рукописных цифр размером 28×28

пикселей в обучающей выборке и 10 000 изображений в тестовой. В качестве меры сходства использовалась евклидова метрика (L_2 -норма) по пиксельным значениям.

В базовом методе «полного перебора» (*англ.* brute-force) для каждого из 10 000 тестовых образцов вычислялись расстояния до всех 60 000 обучающих, что заняло свыше 80 мин на стандартном однопоточном исполнении. При этом доля неверно распознанных символов составила 3,69% (369 ошибок).

В иерархическом методе строилось дерево поиска с фактором разветвления 10 на каждом уровне и глубиной 5. По результатам построения дерева время обработки полного тестового набора сократилось примерно до 0,1 мин (≈ 6 с), что соответствует ускорению более чем в 800 раз. Однако точность упала до 5,64% (564 ошибки) из-за неточности отнесения некоторых образцов к кластерам. На рис. 2 показаны примеры ошибочной классификации и соответствующие ближайшие соседи из обучающего множества. Очевидно, что использование более сложных мер сходства (например, основанных на признаках сверточных сетей) может повысить качество распознавания.




Рис. 2: Примеры изображений из тестового набора MNIST (10 000 образцов), ошибочно классифицированных иерархической нейросетью, и их ближайшие соседи из обучающей выборки (60 000 образцов), найденные с помощью построенного поискового дерева.

6.2 Простейший машинный перевод текста

В качестве второго теста метод был применен к задаче русско-английского перевода субтитров на основе свободно распространяемого набора данных OpenSubtitles v2018 (OPUS). Мы использовали русские и английские тексты субтитров для формирования обучающего массива с соответствующими парами предложений. Каждое предложение преобразовывалось в вектор длины 200: сначала строился словарь токенов, упорядоченный по убыванию частоты, затем каждому слову ставился векторный индекс в этом словаре; если в предложении встречалось менее 200 токенов, оставшиеся позиции заполнялись значением -1 , при превышении – обрезка до первых 200.

По полученным векторам строилось иерархическое дерево с теми же параметрами (ветвление = 10, глубина = 5). В пользовательском интерфейсе вводилось предложение на исходном языке, а в поле вывода отображался «перевод» – ближайший по L_2 -метрике вектор из целевого языка (рис. 3). Хотя такой подход не сопоставим по качеству с современными seq2seq-моделями, он

продемонстрировал принципиальную возможность применения иерархических деревьев в задачах обработки текстовых данных.

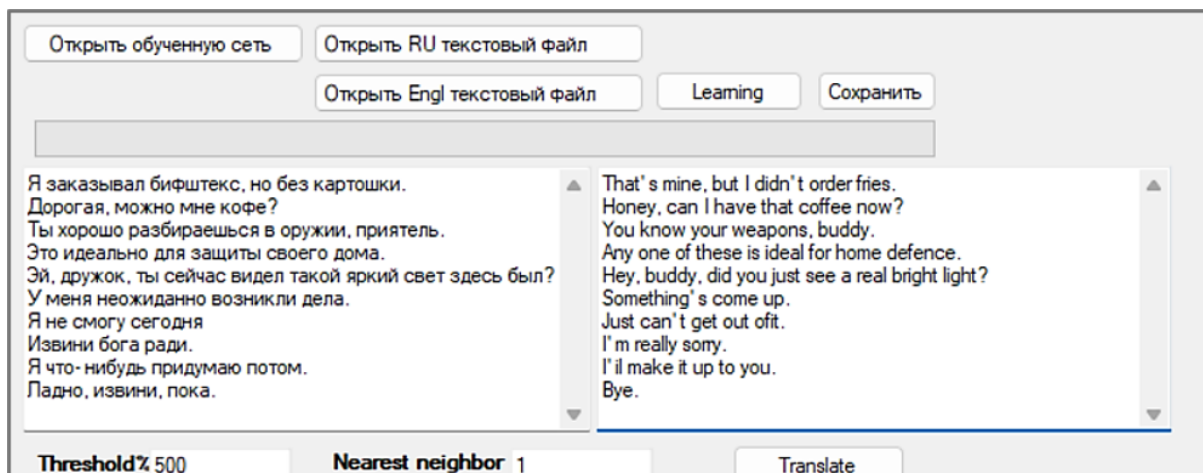


Рис. 3: Результаты тестирования иерархической нейросети как простого переводчика субтитров: в правом окне приведены исходные предложения, в левом – соответствующие переводы. Порог сходства (threshold) задает минимальное значение близости для отбора соседей и позволяет избежать «галлюцинаций», а число ближайших соседей (nearest neighbors) определяет количество альтернативных вариантов перевода.

Ключевое преимущество методики – простота «дообучения»: при поступлении новых пар предложений необходимо лишь обновить словарь токенов и один раз прогнать новые векторы через процедуру обучения (коррекция весов узлов и листьев дерева), без полного переобучения всей структуры.

Таким образом, иерархические нейронные сети на основе ближайшего соседа могут служить эффективным «легким» методом эмбединга (*англ.* embedding) текстов, позволяющим сокращать пространство признаков и сохранять локальные семантические отношения между словами и предложениями.

7 Недостатки иерархических нейронных сетей

При тестировании предлагаемого метода выявлены несколько фундаментальных ограничений и недостатков, оказывающих влияние на точность и производительность этих моделей.

Одним из основных недостатков является неоднозначность кластеризации объектов, расположенных на границах кластеров. В иерархических структурах объекты, находящиеся в пограничных зонах, могут быть неоднозначно отнесены к двум или нескольким кластерам, что приводит к повышению ошибки распознавания по сравнению с методами полного перебора. Данное ограничение обусловлено недостаточной раздельной способностью традиционных жестких алгоритмов кластеризации, таких как аггломеративные и дивизивные методы [18, 25]. Для минимизации этой ошибки предлагается использовать алгоритмы мягкой кластеризации, допускающие принадлежность одного объекта к нескольким кластерам одновременно. Однако это приводит к дополнительному увеличению вычислительной нагрузки, причем степень увеличения напрямую зависит от величины порога принадлежности пограничных объектов, который может задаваться вручную или автоматически на основе статистики данных.

Другим важным ограничением является необходимость хранения полного обучающего масси-

ва. Даже если хранить лишь ссылки на объекты, возможное дублирование пограничных элементов увеличивает требования к объему памяти. Особенно актуальна эта проблема при работе с массивами данных большого размера, такими как тексты для крупных языковых моделей [11, 7]. Хотя современные вычислительные устройства, такие как рабочие станции и ноутбуки, обычно обладают достаточными возможностями хранения, экстремально большие массивы требуют применения облачных хранилищ, что влечет дополнительные затраты на инфраструктуру.

Кроме того, глубокие иерархические структуры с большим количеством узлов на каждом уровне приводят к значительным затратам времени на поиск ближайших соседей. Несмотря на то, что этот процесс легко поддается распараллеливанию на уровне отдельных узлов, общая вычислительная сложность остается высокой, особенно при значительной глубине и ширине иерархии [5].

Также стоит отметить, что иерархические нейронные сети подвержены «проклятию размерности». При увеличении размерности признакового пространства расстояния между объектами становятся менее информативными, что снижает эффективность кластеризации и поиска ближайших соседей. Это ограничение особенно заметно при обработке высокоразмерных признаковых пространств, когда иерархическая структура не всегда демонстрирует преимущество перед плоскими графовыми методами, такими как k -NN с диверсификацией связей [3]. Улучшение результатов может быть достигнуто путем комбинирования иерархической структуры с графовой диверсификацией [29].

Наконец, жесткость решений иерархических деревьев снижает устойчивость модели к шумам и выбросам, особенно в областях данных низкой плотности. Это ограничение усложняет интерпретацию результатов и снижает общую устойчивость классификации. Современные подходы, такие как интерпретируемые алгоритмы k -NN, могут частично решать эту проблему путем анализа соседей в скрытом пространстве эмбедингов, что повышает устойчивость и улучшает интерпретируемость моделей [31].

8 Преимущества иерархических нейронных сетей

Несмотря на недостатки, иерархические нейронные сети характеризуются рядом значительных преимуществ, обусловленных их структурой и принципами организации обучения. Одним из основных преимуществ является линейная зависимость времени обучения от размера обучающей выборки и сложности геометрии сети, которая определяется количеством узлов на уровне и глубиной дерева [28]. Это позволяет эффективно использовать иерархические нейронные сети даже на массивах данных, содержащих миллиарды объектов, без необходимости применения дорогостоящих супервычислительных комплексов [3].

Особо следует выделить **отсутствие проблемы «галлюцинаций»**, характерной для генеративных нейронных моделей, таких как генеративные состязательные сети (*англ.* Generative adversarial network или GAN). В случае иерархических нейронных сетей легко идентифицировать, что запрашиваемые данные отсутствуют в обучающем множестве, поскольку найденный ближайший сосед будет характеризоваться параметром сходства ниже заданного порога [14].

Высокая устойчивость является еще одним важным свойством иерархических нейронных сетей. Даже если произойдет повреждение отдельного элемента, например нейрона или отдельного

коэффициента внутри нейрона, сеть продолжит функционировать, хотя и с частичной потерей информации в отдельных ветвях памяти. Подобное свойство значительно увеличивает надежность системы при ее использовании в критически важных приложениях [19].

Дополнительным преимуществом иерархических нейронных сетей является возможность **анализа совместимости пар обучения**. В листьях иерархической структуры обычно группируются похожие объекты с одинаковой или схожей разметкой. В случае, если разметка у похожих объектов различается, это сигнализирует о недостаточности выбранного векторного представления данных и позволяет выявлять аномальные или ошибочные объекты [21].

Кроме того, иерархические сети предоставляют возможность генерализации идентичных или схожих объектов, что позволяет существенно сократить объем обучающего множества. Генерализация осуществляется путем замены множества сходных объектов одним представительным объектом, тем самым оптимизируя процесс обработки данных и ускоряя обучение сети [6].

Важным достоинством иерархических нейронных сетей является **возможность эффективно дообучения** без эффекта катастрофического забывания, присущего многим другим нейронным архитектурам. Новые объекты можно легко интегрировать в существующее дерево, быстро определяя их оптимальное расположение в иерархии [32].

В случае, если тестируемый объект отличается от ближайшего соседа сильнее заданного порога, он формирует новый узел (лист) в иерархии, что позволяет рассматривать данный объект как новый тип, отличный от уже известных классов. Также следует отметить возможность анализа трендов свойств объектов, находящихся в одном листе, что дает возможность теоретического предсказания существования новых, еще не открытых объектов или классов объектов [17].

Кроме того, иерархические нейронные сети **способны обучаться на небольшом количестве данных**, начиная буквально с одного объекта. Последовательно добавляя объекты и адаптивно формируя новые кластеры на разных уровнях иерархии, иерархические нейронные сети обеспечивают высокую гибкость и адаптивность. Порог схожести, необходимый для кластеризации, может определяться автоматически на основе статистического анализа дисперсии значений близости объектов на разных уровнях дерева [37].

9 Возможные области применения иерархических нейронных сетей

Иерархические нейронные сети успешно применяются в различных областях, демонстрируя эффективность при решении задач прогноза и классификации. Одной из актуальных и успешно реализованных областей применения является прогноз коллекторских свойств горных пород на месторождениях нефти и газа по данным сейсморазведки и измерений в скважинах [1].

Формирование обучающей выборки в таких задачах происходит путем предварительного группирования входных сейсмических данных и целевых прогнозных параметров, полученных из интерпретации данных геофизических исследований скважин. Обучающие данные представляют собой набор пар «сейсмический отклик – прогнозный параметр». При этом в качестве целевого параметра часто используется непрерывное распределение свойств пород, таких как пористость, объемное содержание минеральных компонент или насыщение углеводородами. В частности, среднее значение прогнозного параметра рассчитывается вдоль траектории скважины и сопоставляется с определенной ячейкой регулярной сейсмической сетки (рис. 4).




Рис. 4: Принцип формирования обучающей выборки с использованием скважинных и сейсмических данных.

Сейсмический отклик представляет собой сегмент (окно) сейсмического волнового поля размерностью $m \times n$, где m – число отсчетов по вертикали (во временном или глубинном масштабах), а n – количество соседних трасс. Центр этого окна соответствует местоположению ячейки с прогнозным параметром. Параметры m и n задаются пользователем, а их оптимальные значения подбираются эмпирически в процессе калибровки модели прогноза.

Кластерное дерево решений строится на основе анализа множества сейсмических откликов из обучающей выборки. В корневом узле дерево разделяется на заданное количество кластеров. Далее каждый последующий узел разделяется аналогичным образом до получения конечных «листьев» дерева (рис. 5). Глубина и степень разветвленности дерева определяются пользователем исходя из характера данных и целей прогноза. Использование бинарного деления обеспечивает простоту и скорость поиска, однако многоуровневое разделение на большее число кластеров позволяет точнее описывать сложные взаимосвязи данных. При этом глубина дерева может быть задана автоматически при указании минимального числа объектов в листьях, что оптимизирует структуру сети.

После построения дерева решений осуществляется детальный анализ пар «сейсмический отклик – прогнозный параметр» в листьях дерева. При условии высокой меры подобия сейсмических откликов прогнозные параметры в рамках одного листа также должны быть близки друг другу. Применение метода k-NN позволяет улучшить точность прогноза путем усреднения прогнозных параметров с учетом коэффициентов подобия и пространственной близости соседей. Для дискретных параметров, таких как тип коллектора или литологические фации, прогноз строится на основе наиболее распространенного значения среди ближайших соседей.




Рис. 5: Схема построения кластерного дерева решений в задачах количественной интерпретации данных сейсморазведки.

Низкое подобие прогнозных параметров в пределах одного листа указывает на слабую связь между сейсмическим откликом и прогнозируемым параметром и может служить сигналом к пересмотру выбранной модели или параметров обучения.

При прогнозе на новых данных исходные сейсмические отклики проходят через дерево решений от корневого узла до соответствующего листа, где и определяется прогнозный параметр (рис. 6). Если новый отклик существенно отличается от уже известных, то он помещается в отдельный неразмеченный кластер. Последующие отклики, близкие к нему, объединяются в этот кластер. Такой подход обеспечивает автоматическое дообучение сети и адаптацию модели к новым, ранее неизвестным типам данных.




Рис. 6: Пример прогноза пористости предложенным методом иерархических нейронных сетей по сейсмическим данным.

Таким образом, иерархические нейронные сети позволяют эффективно решать задачи анализа и прогноза в нефтегазовой отрасли, обеспечивая высокую точность, гибкость и возможность непрерывного обучения.

Мы также считаем, что предлагаемая технология может быть успешно использована в различных областях, где получение ошибочного («галлюцинирующего») результата с применением традиционных нейросетевых подходов крайне критично:

- **Диагностика в медицинских исследованиях**, основанная на анализе больших массивов данных. В данной области критически важно избежать неправильных диагнозов, вызванных эффектом «галлюцинации». С помощью предлагаемой технологии можно находить несколько близких наборов медицинских данных (например, анализов и исследований), соответствующих определенным диагнозам. Сравнительный анализ степени схожести новых тестируемых данных с ранее установленными случаями (ближайшими соседями) позволит более точно оценить вероятность правильного диагноза и снизить риск диагностических ошибок [12].
- **Анализ научных данных и результатов исследований** на основе больших информационных баз данных. Применение технологии позволит эффективно выявлять уникальность и новизну результатов исследований, избегая дублирования и повышая качество научных заключений [23].
- **Создание систем машинного перевода** на основе больших баз параллельных текстов на разных языках. Для эффективного сравнения текстовых предложений необходима их предварительная векторизация с использованием подходов, таких как эмбединг и механизмы «внимания». Предлагаемая технология обеспечит повышение точности перевода и снижение вероятности ошибочных результатов, связанных с эффектом «галлюцинаций» [36].
- **Разработка специализированных LLM** для генерации и прогнозирования контекстного продолжения предложений. В таких системах требуется векторизация текстовых данных с использованием эмбедингов и механизмов «внимания». Применение описанной технологии позволит существенно снизить вероятность появления галлюцинаций и обеспечит простоту и эффективность дообучения моделей без риска катастрофического забывания, что особенно важно при работе с непрерывно поступающими новыми текстовыми данными [7].
- **Управление критически важными технологическими процессами**, где ошибки традиционных нейронных сетей могут привести к серьезным последствиям, например, в ядерной энергетике, химической промышленности и других подобных отраслях. В таких условиях особенно важно обеспечить высокую достоверность прогноза состояний технологических процессов, минимизируя риск возникновения эффектов галлюцинации.

Предложенная технология может быть адаптирована и для решения широкого спектра других задач, где применение классических нейронных сетей ограничено недостатками, связанными с галлюцинациями и проблемами непрерывного дообучения.

10 Обсуждение

Очевидно, что в основе нашего мышления лежит метод аналогий. Сталкиваясь с новыми объектами или явлениями, мы неизбежно пытаемся найти аналоги среди уже известных нам образов, хранящихся в нашей памяти. Если обнаруживается достаточная схожесть нового объекта или явления с уже известными, мы укрепляем и подтверждаем наши текущие знания. В противном случае, когда аналогии не находятся или обнаруживаются лишь отдаленные связи, мы воспринимаем такие объекты или явления как новые, уникальные. Именно они становятся базой для формирования совершенно новых знаний и понятий.

В контексте познания окружающего мира важно отметить, что человеческое мышление имеет склонность группировать и классифицировать информацию. Мы систематизируем сходные объекты или явления, образуя обобщенные категории, что значительно упрощает и ускоряет дальнейший процесс познания. Для определения, является ли предъявленное явление или объект действительно новым, мы вынуждены сопоставлять его с ранее сформированными иерархическими структурами знаний, имеющими различные уровни генерализации. Эти структуры обычно обладают расширяющейся формой, где от наиболее общих понятий («корневые узлы») иерархия постепенно уточняется до более частных и конкретных элементов, хранящихся в «листьях» такой структуры. Подобная архитектура позволяет оперативно и эффективно сопоставлять, и идентифицировать новые поступающие данные.

Перспективным выглядит применение математических методов, основанных на подходах иерархических нейронных сетей и алгоритме ближайшего соседа, для более глубокого изучения и моделирования процесса человеческого мышления. В частности, такие нейросетевые модели позволяют структурировать данные аналогично тому, как это делает человеческий мозг, и оценивать сходство новых данных с уже имеющимися, используя меры расстояний или меры сходства. Используя иерархические нейронные сети, мы можем приблизиться к пониманию того, как мозг человека категоризирует знания, запоминает информацию и извлекает из нее необходимые аналогии для познания окружающего мира. Применение нейронных сетей может также пролить свет на механизм возникновения новых понятий и креативного мышления, основывающегося на поиске неожиданных аналогий и связей между явлениями и объектами, казавшимися ранее несвязанными.

Возможно, что дальнейшее развитие математических и компьютерных моделей мышления с помощью иерархических нейронных сетей позволит нам не только улучшить технологические подходы к обработке данных, но и приблизиться к разгадке фундаментальных вопросов о природе человеческого интеллекта и мышления.

11 Заключение

В настоящей работе предложен альтернативный подход к решению задач искусственного интеллекта, основанный на использовании иерархических нейронных сетей с алгоритмом ближайшего соседа. Несмотря на то, что алгоритм ближайшего соседа по сравнению с классическими нейронными сетями является более простым и, возможно, менее инновационным методом, его применение может существенно снизить или полностью устранить эффект «галлюцинаций», характерный для современных глубоких нейронных сетей. Эта особенность чрезвычайно важна в областях, где высокая достоверность результатов является критически значимой.

Основное отличие нейронных сетей от алгоритма ближайшего соседа заключается в том, что нейронные сети стремятся обобщать и аппроксимировать обучающие данные посредством огромного количества взаимосвязанных параметров, что требует значительных вычислительных и временных ресурсов. В то же время метод ближайшего соседа рассматривает каждую пару обучающих данных независимо, что позволяет работать даже с противоречивыми наборами данных без потери стабильности и надежности результата. Такой подход обеспечивает прозрачность принимаемых решений и легкость интерпретации результатов, так как итоговый ответ всегда связан с конкретными примерами из обучающей выборки.

Предложенный метод демонстрирует высокую вычислительную эффективность, значительно превосходя наивную реализацию алгоритма k-ближайших соседей и не уступая при этом классическим нейросетевым моделям в задачах прогнозирования и классификации. Алгоритм построения поискового дерева на основе самоорганизующихся карт Кохонена позволяет структурировать данные, существенно сокращая время поиска ближайших аналогов.

Особую перспективность предложенный подход демонстрирует в области обработки текстовых данных, где использование технологий эмбединга и механизмов «внимания» является обязательным условием. Применение иерархических сетей обеспечивает линейную зависимость вычислительных затрат от размера обучающих данных и сложности самой сети, что выгодно отличает данный подход от традиционных нейронных сетей, требующих значительных вычислительных мощностей для обучения и выполнения вывода. Таким образом, предлагаемый подход не только преодолевает фундаментальные ограничения традиционных нейросетевых технологий, но и открывает новые перспективы для создания устойчивых, интерпретируемых и надежных систем искусственного интеллекта. Дополнительным преимуществом является близость предложенного алгоритма к принципам человеческого мышления, которое также основано на использовании аналогий и иерархическом структурировании знаний. Это позволяет рассчитывать на успешное развитие данной методики не только в прикладных задачах, но и в фундаментальных исследованиях механизмов человеческого интеллекта и познания.

Благодарности

Авторы благодарят своих коллег из ООО «Лаборатория Приезжева» за совместную работу и помощь в исследованиях.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Литература

- [1] Приезжев, И. И. Иерархические нейронные сети в задачах прогноза свойств коллекторов нефти и газа по скважинным и сейсмическим данным / И. И. Приезжев, Д. А. Данько, А. Н. Онищенко // *Геология и геофизика*. – 2025. – Т. 66, № 1. – С. 131-140. – DOI 10.15372/GiG2024141. – EDN QHBLVO.

- [2] C.C. Aggarwal, A. Hinneburg, and D.A. Keim, “On the surprising behavior of distance metrics in high dimensional space,” *Database Theory—ICDT 2001*, Springer, pp. 420–434, 2001.
- [3] C.C. Aggarwal, *Data Mining: The Textbook*, Springer, 2015.
- [4] J.L. Bentley, “Multidimensional binary search trees used for associative searching,” *Communications of the ACM*, vol. 18, no. 9, pp. 509–517, 1975.
- [5] K. Beyer, J. Goldstein, R. Ramakrishnan, and U. Shaft, “When is ‘nearest neighbor’ meaningful?” in *Database Theory—ICDT’99*, Springer, pp. 217–235, 1999.
- [6] C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [7] T. Brown, B. Mann, N. Ryder, M. Subbiah, J.D. Kaplan, P. Dhariwal, A. Neelakantan, P. Shyam, G. Saxena, S. Santurkar, *et al.*, “Language models are few-shot learners,” *Advances in Neural Information Processing Systems*, vol. 33, pp. 1877–1901, 2020.
- [8] J. Buolamwini and T. Gebru, “Gender shades: Intersectional accuracy disparities in commercial gender classification,” in *Conference on Fairness, Accountability and Transparency*, PMLR, pp. 77–91, 2018.
- [9] V. Chandola, A. Banerjee, and V. Kumar, “Anomaly detection: A survey,” *ACM Computing Surveys*, vol. 41, no. 3, pp. 1–58, 2009.
- [10] T. Cover and P. Hart, “Nearest neighbor pattern classification,” *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21–27, 1967.
- [11] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” *arXiv preprint arXiv:1810.04805*, 2018.
- [12] A. Esteva, B. Kuprel, R.A. Novoa, J. Ko, S.M. Swetter, H.M. Blau, and S. Thrun, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, 2017.
- [13] E. Fix and J.L. Hodges Jr., “Discriminatory analysis. Nonparametric discrimination: consistency properties,” Tech. Rep. 4, Project 21-49-004, USAF School of Aviation Medicine, Randolph Field, TX, 1951.
- [14] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, 2016.
- [15] D. Gunning, “Explainable artificial intelligence (XAI),” Defense Advanced Research Projects Agency (DARPA), Tech. Rep., 2017.
- [16] C. Guo, G. Pleiss, Y. Sun, and K.Q. Weinberger, “On calibration of modern neural networks,” in *International Conference on Machine Learning*, PMLR, pp. 1321–1330, 2017.
- [17] J. Han, J. Pei, and M. Kamber, *Data Mining: Concepts and Techniques*, 3rd ed., Morgan Kaufmann, 2011.
- [18] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed., Springer Science & Business Media, 2009.

- [19] S.S. Haykin, *Neural Networks and Learning Machines*, 3rd ed., vol. 3, Pearson, 2009.
- [20] E.J. Hu, Y. Shen, P. Wallis, Z. Allen-Zhu, Y. Li, S. Wang, L. Wang, and W. Chen, “LoRA: Low-Rank Adaptation of Large Language Models,” *arXiv preprint arXiv:2106.09685*, 2022.
- [21] A.K. Jain and R.C. Dubes, *Algorithms for Clustering Data*, Prentice-Hall, 1988.
- [22] Z. Ji, N. Lee, R. Frieske, T. Yu, D. Su, Y. Xu, E. Ishii, Y.J. Bang, A. Madotto, and P. Fung, “Survey of hallucination in natural language generation,” *ACM Computing Surveys*, vol. 55, no. 12, pp. 1–38, 2023.
- [23] M.I. Jordan and T.M. Mitchell, “Machine learning: Trends, perspectives, and prospects,” *Science*, vol. 349, no. 6245, pp. 255–260, 2015.
- [24] J. Kaplan, S. McCandlish, T. Henighan, T.B. Brown, B. Chess, R. Child, S. Gray, A. Radford, J. Wu, and D. Amodei, “Scaling laws for neural language models,” *arXiv preprint arXiv:2001.08361*, 2020.
- [25] L. Kaufman and P.J. Rousseeuw, *Finding Groups in Data: An Introduction to Cluster Analysis*, John Wiley & Sons, 1990.
- [26] J. Kirkpatrick, R. Pascanu, N. Rabinowitz, J. Veness, G. Desjardins, A.A. Rusu, K. Milan, J. Quan, T. Ramalho, A. Grabska-Barwinska, *et al.*, “Overcoming catastrophic forgetting in neural networks,” *Proceedings of the National Academy of Sciences*, vol. 114, no. 13, pp. 3521–3526, 2017.
- [27] T. Kohonen, *Self-Organizing Maps*, 3rd ed., vol. 30, Springer, 1995.
- [28] D. Koller and N. Friedman, *Probabilistic Graphical Models: Principles and Techniques*, MIT Press, 2009.
- [29] S. Luan, M. Zhao, X.-W. Chang, and D. Precup, “Complete the missing half: Augmenting aggregation filtering with diversification for graph convolutional networks,” *arXiv preprint arXiv:2008.08844*, 2020.
- [30] Y.A. Malkov and D.A. Yashunin, “Efficient and robust approximate nearest neighbor search using hierarchical navigable small world graphs,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 42, no. 4, pp. 824–836, 2020.
- [31] N. Papernot and P. McDaniel, “Deep k-nearest neighbors: Towards confident, interpretable and robust deep learning,” *arXiv preprint arXiv:1803.04765*, 2018.
- [32] G.I. Parisi, R. Kemker, J.L. Part, C. Kanan, and S. Wermter, “Continual lifelong learning with neural networks: A review,” *Neural Networks*, vol. 113, pp. 54–71, 2019.
- [33] I.I. Priezzhev, A.I. Fedorov, A.A. Shevchenko, and A.N. Onishchenko, “Seismic waveform classification based on Kohonen 3D neural networks with RGB visualization,” *First Break*, vol. 37, no. 2, pp. 37–43, 2019.

- [34] E. Strubell, A. Ganesh, and A. McCallum, “Energy and policy considerations for deep learning in NLP,” *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pp. 3645–3650, 2019.
- [35] C. Szegedy, W. Zaremba, I. Sutskever, J. Bruna, D. Erhan, I. Goodfellow, and R. Fergus, “Intriguing properties of neural networks,” *arXiv preprint arXiv:1312.6199*, 2013.
- [36] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” *Advances in Neural Information Processing Systems*, vol. 30, pp. 5998–6008, 2017.
- [37] R. Xu and D. Wunsch, “Survey of clustering algorithms,” *IEEE Transactions on Neural Networks*, vol. 16, no. 3, pp. 645–678, 2005.
- [38] C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals, “Understanding deep learning requires rethinking generalization,” *arXiv preprint arXiv:1611.03530*, 2016.