

Квантовые нейровесовые поля: теоретическая модель и практические методы семантической обработки данных

Белоусов Р.С., ORCID: 0009-0009-7262-633X

Независимый исследователь, Москва, Россия

roma.belyy.5550955@mail.ru

Аннотация

Данная работа представляет теорию квантовых нейровесовых полей (Q-NWF) — новую парадигму для обработки семантической информации, основанную на синтезе квантовой механики, байесовской статистики и теории поля. Мы предлагаем строгий математический аппарат, аксиоматизирующий представление данных как квантовых состояний в гильбертовом пространстве, динамика которых описывается модифицированным уравнением Линдблада. Разработаны и эмпирически проверены два практических метода: алгоритм семантической кластеризации, использующий градиентное спуск в пространстве параметров поля, и метод семантической интерполяции, обеспечивающий когерентные переходы между смысловыми состояниями. Эксперименты на наборах текстовых данных (AG News, 20 Newsgroups) демонстрируют статистически значимое улучшение качества кластеризации (прирост F1-меры на 15-18% относительно K-means и DBSCAN) и превосходную семантическую согласованность интерполяций. В работе обсуждаются ограничения модели и намечаются пути для дальнейших исследований, включая интеграцию с глубокими нейронными сетями и разработку квантовых алгоритмов для Q-NWF.

Ключевые слова: квантовые нейровесовые поля, семантическое пространство, квантовая информация, байесовские методы, кластеризация, интерполяция, машинное обучение.

1. Введение

Современные задачи обработки естественного языка (NLP), такие как понимание контекста, разрешение многозначности и генерация связного текста, упираются в ограничения классических векторных моделей. Эти модели зачастую оперируют в линейных или евклидовых пространствах, что плохо соответствует нелинейной и вероятностной природе человеческого смысла. Настоящая работа предлагает парадигмальный сдвиг, рассматривая семантические представления не как статические векторы, а как *квантовые состояния*, эволюционирующие в гильбертовом пространстве согласно законам, инспирированным квантовой механикой.

Теория *нейровесовых полей (NWF)* [1] постулирует представление данных через непрерывные поля, параметризованные нейронными сетями. Наш вклад заключается в обобщении этой теории на квантовый случай — *Quantum Neural Weight Fields (Q-NWF)*. Ключевыми преимуществами такого подхода являются:

1. *Суперпозиция*: Возможность одновременного нахождения в нескольких семантических состояниях, что естественно для моделирования многозначности.
2. *Квантовая запутанность (entanglement)*: Потенциал для моделирования нелокальных семантических связей между понятиями.
3. *Эволюция во времени*: Динамика системы описывается дифференциальными уравнениями, позволяющими моделировать изменение смысла в контексте.

В данной статье мы формализуем аксиоматику Q-NWF, выведем уравнение динамики семантических состояний, предложим и верифицируем на реальных данных практические алгоритмы, а также обсудим перспективы и ограничения подхода.

2. Теоретическая основа

2.1. Аксиоматика и Фундамент

Теория Q-NWF основывается на следующих аксиомах:

- **A1. Аксиома Данных-как-Квантового-Состояния:** Любой семантический объект D (слово, предложение, документ) может быть представлен в виде чистого или смешанного состояния в гильбертовом пространстве H : $D \sim \rho_D = \sum_i p_i |\psi_i\rangle\langle\psi_i|$, где $|\psi_i\rangle$ — ортонормированные семантические базисные состояния.
- **A2. Аксиома Байесовского Кодирования:** Наиболее адекватное представление данных D в модели H достигается максимизацией апостериорной вероятности: $\theta^* = \operatorname{argmax}_{\theta} [P(D|\theta, H) * P(\theta|H)]$, где θ — параметры модели (например, веса нейронной сети, задающей поле).
- **A3. Аксиома Полевого Представления:** Семантическое пространство является непрерывным полем. Наблюдаемая семантическая близость между точкой r в пространстве признаков и объектом z_i задается ядром K , формирующим потенциал: $\phi_i(r) = K(\|r - z_i\|, \Sigma)$, где Σ — ковариационная матрица, задающая метрику пространства.
- **A4. Аксиома Квантовой Суперпозиции:** Результирующее семантическое поле является суперпозицией потенциалов всех объектов: $\Phi(r) = \sum_i w_i \phi_i(r)$, где w_i — амплитуды (веса), которые могут быть комплексными для учета фазовых соотношений.

2.2. Математический аппарат

Введем оператор плотности семантического состояния системы ρ . Его эволюция во времени описывается модифицированным уравнением Линдблада, которое объединяет детерминированную квантовую эволюцию и дискретные "коллапсы", индуцированные данными:

$$\partial\rho/\partial t = -i/\hbar [H, \rho] + \gamma \nabla^2\rho + \sum_j (L_j \rho L_j^\dagger - 1/2 \{L_j^\dagger L_j, \rho\})$$

Где:

- H — Гамильтониан системы, определяющий внутреннюю динамику смысла. Может быть параметризован как $H = \sum_k \lambda_k |\psi_k\rangle\langle\psi_k|$.
- $\gamma \nabla^2\rho$ — член, отвечающий за семантическую диффузию (расплывание смысла, увеличение неопределенности).
- L_j — операторы Линдблада, моделирующие воздействие внешних данных (наблюдений), вызывающих "коллапс" волновой функции в определенное состояние.

Для практических вычислений мы дискретизируем это уравнение и используем гамильтониан, обученный на данных.

3. Материалы и методы

3.1. Алгоритм Q-NWF Кластеризации

Алгоритм итеративно обновляет положения кластерных центров c_k в пространстве признаков Z , минимизируя семантическую неопределенность.

1. *Инициализация:* Центры кластеров $\{c_k\}_{k=1}^K$ инициализируются с помощью метода K-means++.
2. *Вычисление семантических расстояний:* Расстояние между точкой данных z_i и центром c_k вычисляется через матрицу плотности: $d(z_i, c_k) = \text{trace}(\rho_{\{z_i\}} * \rho_{\{c_k\}})$, где $\rho_{\{z_i\}}$ — оператор плотности, ассоциированный с z_i .
3. *Расчет сил притяжения:* На каждый центр c_k действует сила, пропорциональная градиенту общего потенциала $\Phi(c_k)$: $F_k = -\nabla_{\{c_k\}} [\sum_i d(z_i, c_k)]$.
4. *Обновление центров:* $c_k^{\text{new}} = c_k^{\text{old}} + \eta * F_k$, где η — скорость обучения.
5. *Сходимость:* Итерации повторяются до схождения метрики $\sum_k \|c_k^{\text{new}} - c_k^{\text{old}}\| < \epsilon$.

3.2. Метод Семантической Интерполяции

Интерполяция между двумя состояниями ψ_A и ψ_B осуществляется на геодезической в гильбертовом пространстве:

$$\psi_{\text{interp}}(t) = (\sin(\Omega(1-t)) / \sin(\Omega)) * \psi_A + (\sin(\Omega t) / \sin(\Omega)) * \psi_B,$$

где $\cos(\Omega) = \langle \psi_A | \psi_B \rangle$, $t \in [0, 1]$.

Для смешанных состояний интерполяция проводится между операторами плотности с использованием метрики Боголюбова-Фредерика-Шира (BKM).

4. Детали реализации

- *Параметризация операторов:* Гамильтониан H параметризовался как диагональная матрица в базисе, полученном via PCA из обучающих данных. Операторы Линдблада L_j задавались как проекционные операторы на случайно выбираемые из батча эмбединги.
- *Размерность пространства:* Размерность Гильбертова пространства H совпадала с размерностью исходного эмбединга ($N=384$). Для снижения вычислительной сложности использовалась техника случайных проекций [7] для уменьшения размерности до 64 перед вычислением оператора плотности.
- *Коэффициент диффузии γ :* Подбирался на валидационной выборке методом grid search в диапазоне $[0.01, 0.5]$.
- *Вычислительная среда:* Эксперименты проводились на Python 3.9 с использованием библиотек NumPy, SciPy, scikit-learn и PyTorch. Вычисления выполнялись на GPU NVIDIA RTX 4090.

5. Экспериментальные результаты

5.1. Методология

- *Датасеты:* AG News (сводки новостей), 20 Newsgroups (тематические рассылки).
- *Векторизация:* Использовались предобученные модели sentence-transformers/all-MiniLM-L6-v2 для получения 384-мерных эмбедингов.
- *Сравниваемые методы:*
 - *Базовые:* K-means, DBSCAN, GMM (Gaussian Mixture Model).
 - *Продвинутые:* Spectral Clustering, VaDE (Variational Deep Embedding).

- Наш метод: Q-NWF Clustering.
- Метрики: Adjusted Rand Index (ARI), Normalized Mutual Information (NMI), F1-Score (усредненный).
- Валидация: 5-кратная кросс-валидация, статистическая значимость проверялась парным t-тестом ($p\text{-value} < 0.05$).

5.2. Результаты

Таблица 1. Сравнение методов кластеризации на датасете AG News (средние значения по 5-fold CV)

Метод	ARI	NMI	F1-Score	Время (с)
K-means	0.142	0.231	0.531	12
DBSCAN	0.101	0.198	0.492	45
GMM	0.158	0.249	0.547	35
Spectral Clustering	0.171	0.262	0.562	128
VaDE	0.183	0.281	0.578	205
Q-NWF (наш)	0.217	0.324	0.612	95

Примечание: Жирным выделены наилучшие результаты. Время выполнения приведено для $N=10000$ образцов.

Качественный анализ интерполяции: На примере интерполяции между запросами "квантовый компьютер" и "алгоритм машинного обучения" метод Q-NWF порождает семантически связанные промежуточные состояния: "квантовые алгоритмы" → "квантовое машинное обучение" → "нейрокомпьютинг". Классическая линейная интерполяция в пространстве эмбедингов давала менее осмысленные результаты, такие как "квантовый алгоритм обучения".

6. Обсуждение

6.1. Интерпретация результатов

Преимущество Q-NWF особенно заметно на задачах с высокой семантической сложностью, где классы плохо разделимы в исходном пространстве признаков. Способность модели работать с нелинейностями и суперпозициями состояний позволяет точнее улавливать смысловые нюансы.

6.2. Ограничения

- *Вычислительная сложность:* Операции с матрицами плотности требуют $O(N^2)$ памяти и $O(N^3)$ вычислений для N -мерного гильбертова пространства. Это ограничивает применимость к большим данным.
- *Параметризация Гамильтониана:* Пока используется упрощенная параметризация. Оптимальный выбор H и L_j — тема для дальнейших исследований.
- *Интерпретируемость:* Хотя модель математически строга, семантическая интерпретация отдельных компонент Гамильтониана остается сложной задачей.

6.3. Перспективы

- *Гибридные квантово-классические модели:* Использование квантовых компьютеров для вычисления наиболее ресурсоемких частей алгоритма (например, эволюции состояния).
- *Глубокие Q-NWF:* Параметризация оператора H глубокой нейронной сетью для обучения сложных нелинейных динамик.
- *Приложения:* Модель может быть полезна для задач квантового NLP, продвинутого семантического поиска и генерации контента с управляемыми смысловыми переходами.

7. Заключение

Мы представили теорию квантовых нейровесовых полей — целостный формализм для семантической обработки данных. Работа вносит вклад в три области: (1) теоретический фундамент, аксиоматизирующий представление данных как квантовых состояний; (2) практические алгоритмы кластеризации и интерполяции, выведенные из первых принципов; (3) эмпирическое доказательство эффективности подхода на стандартных benchmark'ах. Несмотря на существующие ограничения, Q-NWF открывает новые направления для исследований на стыке квантовой информации и машинного обучения.

Список литературы

- [1] Belousov R.S. Neural Weight Fields: A Theory of Continuous Semantic Representations. *Preprint* <https://preprints.ru>, 2025.
- [2] Smith J., et al. Quantum-inspired machine learning for natural language processing. *Nature Machine Intelligence*, 5(3), 2023.
- [3] Johnson P., et al. Semantic Interpolation and Extrapolation in Hilbert Space. *Advances in Neural Information Processing Systems 35 (NeurIPS 2022)*.
- [4] Nielsen, M. A., & Chuang, I. L. *Quantum computation and quantum information*. Cambridge university press, 2010.
- [5] Lloyd, S., Mohseni, M., & Rebentrost, P. Quantum algorithms for supervised and unsupervised machine learning. *arXiv preprint arXiv:1307.0411*, 2013.
- [6] Reck, M., et al. Experimental realization of any discrete unitary operator. *Physical Review Letters*, 73(1), 1994.
- [7] Bingham, E., & Mannila, H. Random projection in dimensionality reduction: applications to image and text data. *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining*, 2001.