

Графовые нейросети в развитии теории семантико-ассоциативного анализа текстовых данных

О. И. Захарова, Д. В. Гукасян

Поволжский государственный университет телекоммуникаций и информатики

Аннотация: В статье рассматривается роль графовых нейронных сетей (GNN) как нового вычислительного инструмента в развитии теории семантико-ассоциативного анализа текстовых данных. GNN позволяют формализовать ассоциативные связи между лексическими и концептуальными единицами в виде динамических семантических графов, что приближает машинные модели к моделированию отдельных аспектов когнитивной обработки языка. Предложена концептуальная архитектура на основе Graph Attention Networks, интегрирующая лингвистические зависимости и внешние семантические знания, что обеспечивает контекстную адаптацию и интерпретируемость анализа. Обосновывается теоретический вклад GNN в преодоление ограничений традиционных статистических и векторных моделей: переход от изолированных представлений слов к моделированию распространения смысловой активации по сети ассоциаций. Результаты предварительных экспериментов (на основе синтетических данных и корпуса RuSentiment) демонстрируют повышение точности семантической классификации и интерпретируемости выводов. Статья вносит вклад в междисциплинарный синтез компьютерной лингвистики, когнитивной науки и машинного обучения, открывая путь к построению вычислимых теорий смыслопорождения в текстах.

Ключевые слова: графовые нейронные сети, семантико-ассоциативный анализ, семантические графы, машинное обучение, обработка естественного языка, GAT, когнитивное моделирование.

Для цитирования: Захарова О. И., Гукасян Д. В. Графовые нейросети в развитии теории семантико-ассоциативного анализа текстовых данных // Вестник СибГУТИ. 2026. Т. 20, № 2. С. 16–27. <https://doi.org/10.55648/1998-6920-2026-20-2-16-27>.



Контент доступен под лицензией
Creative Commons Attribution 4.0
License

© Захарова О. И., Гукасян Д. В., 2026

Статья поступила в редакцию 20.03.2026;
переработанный вариант – 21.04.2026;
принята к публикации 05.05.2026.

1. Введение

Современные методы анализа текстовых данных, несмотря на значительный прогресс в области машинного обучения и обработки Natural Language Processing, по-прежнему сталкиваются с фундаментальной проблемой – неспособностью в полной мере моделировать семантическую глубину и ассоциативную природу человеческого понимания языка. Преобладающие подходы, основанные на статистических моделях распределённой семантики (Word2Vec, GloVe) или трансформерах (BERT, GPT), хотя и демонстрируют высокую эффективность в задачах классификации и генерации текста, оперируют, как правило, изолированными векторными представлениями слов или предложений, не учитывая сложную сеть смысловых и ассоциативных связей, формирующих контекст и коннотации.

Между тем, в когнитивной лингвистике и психолингвистике давно утвердилась идея, что смысл в языке возникает не в отдельных лексемах, а в системе их ассоциативных отно-

шений – будь то синтагматические, парадигматические, каузальные или культурно-коннотативные связи.

Появление Graph Neural Networks открыло принципиально новые возможности для преодоления этого разрыва между когнитивными теориями и вычислительными моделями. GNN позволяют естественным образом представлять текст как семантический граф, где узлы – это слова, сущности или концепты, а рёбра – различные типы смысловых и структурных связей. Благодаря механизму агрегации информации от соседей GNN способны моделировать распространение активации по ассоциативной сети, динамически адаптируя представления узлов под контекст – что делает их идеальным инструментом для реализации идей семантико-ассоциативного анализа в вычислимой форме.

Целью настоящей статьи является теоретическое обоснование и концептуальная реализация применения графовых нейронных сетей для развития теории семантико-ассоциативного анализа текстовых данных.

Статья вносит вклад в междисциплинарное поле на стыке компьютерной лингвистики, когнитивной науки и машинного обучения, предлагая не просто новый алгоритм, но и перспективный подход к моделированию семантических зависимостей, основанный на динамических, структурированных, интерпретируемых семантических сетях, приближающих машинное понимание к человеческому.

2. Теоретическая часть

Семантико-ассоциативный анализ текстовых данных – это методологический подход, в основе которого лежит представление о том, что смысл единицы языка (слова, фразы, предложения) определяется не изолированно, а через систему ассоциативных связей с другими смысловыми единицами. Этот подход уходит корнями в работы советских и зарубежных психологов и лингвистов – А. А. Леонтьева [1], Дж. Р. Андерсона [2], а также в теорию семантических сетей и spreading activation. Центральным механизмом когнитивных моделей понимания является распространение активации по семантической сети: при восприятии слова активируются не только его прямые значения, но и ассоциированные концепты, усиливая или ослабляя соседние узлы. Механизм message passing в графовых нейросетях представляет собой вычислительную реализацию этой идеи, позволяя моделировать динамику смысловой активации в формализованной форме [17].

Центральной идеей является то, что при восприятии слова в сознании активируются не только его прямые значения, но и ассоциированные с ним концепты, образующие своего рода «ассоциативное поле». Например, слово «чай» может активировать концепты «рассвет», «пробуждение», «сахар».

В рамках компьютерной лингвистики попытки формализовать семантико-ассоциативные связи предпринимались через:

1. статистические модели ассоциаций (Pointwise Mutual Information, Latent Semantic Analysis), которые описывают Church K.W. и Hanks P. в работе «Word association norms, manual information, and lexicography» [3];
2. лексические базы и онтологии (WordNet, ConceptNet, BabelNet), описанные в рамках работы для 11-го Международного семинара по семантической оценке [4];
3. психолингвистические нормы (Русский ассоциативный словарь [5]).

Однако все эти подходы сталкиваются с рядом фундаментальных ограничений:

1. Статичность: связи в онтологиях и словарях фиксированы и не адаптируются под контекст конкретного текста.
2. Изолированность: традиционные векторные модели (Word2Vec, BERT) кодируют слова в изолированные эмбединги, игнорируя структуру связей. Попытки интеграции внешних знаний в трансформерные архитектуры предпринимались в моделях типа ERNIE, где сущности из онтологий встраиваются непосредственно в процесс предобучения. Однако в таких подходах связи между сущностями остаются фиксированными, тогда как предлагаемая

архитектура на основе GAT позволяет динамически перераспределять внимание между ассоциациями в зависимости от контекста конкретного текста [14].

3. Недостаток интерпретируемости: современные трансформеры, несмотря на высокую точность, работают как «чёрные ящики», не позволяя проследить, почему было принято то или иное решение.

4. Отсутствие динамики распространения активации – ключевого механизма когнитивных моделей.

Таким образом, семантико-ассоциативный анализ нуждается в новом вычислительном аппарате, способном:

1. динамически моделировать связи между концептами в зависимости от контекста;
2. интегрировать внешние знания и эмпирические данные;
3. обеспечивать интерпретируемость решений через анализ структуры связей.

Graph Neural Networks – это класс нейросетевых моделей, разработанных для обработки данных, структурированных в виде графов. В отличие от традиционных архитектур (CNN, RNN), GNN работают с нерегулярными, нерешётчатыми структурами, где каждый узел связан с произвольным числом соседей [6].

Как отмечается в современном обзоре [10] по архитектурам графовых нейросетей, ключевым преимуществом GNN является способность работать с нерегулярными структурами данных, сохраняя при этом возможность обучения представлений узлов через механизмы агрегации соседей. Это делает их особенно релевантными для задач моделирования семантических сетей, где связи между концептами не подчиняются жёсткой топологии.

Основной принцип работы GNN – message passing. На каждой итерации узел агрегирует информацию от своих соседей, обновляет своё внутреннее состояние (эмбединг) и передаёт его дальше. После нескольких итераций каждый узел «знает» не только о себе, но и о своём окружении – вплоть до нескольких «прыжков» по графу.

Наиболее релевантные для задач NLP архитектуры:

1. Graph Convolutional Network применяет свёрточные операции на графах, но с фиксированными весами соседей [7].
2. Graph Attention Network использует механизм внимания для динамического взвешивания важности соседей, что обеспечивает интерпретируемость и адаптивность [8].
3. GraphSAGE подходит для крупных графов, работает с выборкой соседей [9].

В контексте семантико-ассоциативного анализа GAT является наиболее перспективной архитектурой, поскольку:

- 1) позволяет модели «обращать внимание» на наиболее значимые ассоциативные связи в конкретном контексте;
- 2) обеспечивает визуализацию и объяснение решений через анализ attention-весов;
- 3) легко интегрируется с гетерогенными графами, содержащими разные типы узлов и рёбер (слова, сущности, концепты, синтаксические и семантические связи).

Слияние GNN и семантико-ассоциативного подхода не случайно – оно логически обосновано на нескольких уровнях:

1) Структурный уровень. Ассоциативные связи естественным образом моделируются как графы. Узлы – слова/концепты, рёбра – типы связей (лексические, семантические, каузальные, культурные). Это позволяет формализовать интуитивные представления о «сети значений».

2) Когнитивный уровень. Механизм message passing в GNN имитирует spreading activation – ключевой процесс в когнитивных моделях памяти и понимания. Активация от одного концепта «распространяется» по связям, усиливая или ослабляя соседние узлы – точно так же, как в человеческом сознании.

3) Вычислительный уровень. GNN позволяют обучать динамические представления узлов, которые зависят не только от самого слова, но и от его позиции в семантической сети. Это преодолевает главный недостаток статических эмбедингов – их контекстную слепоту.

4) Интерпретационный уровень. В отличие от трансформеров, GNN (особенно GAT) позволяют проследить путь влияния: какие узлы и связи повлияли на финальное решение. Это критически важно для семантико-ассоциативного анализа, где нужно не просто классифицировать текст, но и объяснить, какие ассоциации привели к такому смыслу.

Подход к анализу attention-весов как способа объяснения решений модели согласуется с методологией объяснимого ИИ для графовых сетей. В частности, в работе [15] показано, что выделение подграфа наиболее влиятельных узлов и рёбер позволяет генерировать интерпретируемые объяснения для предсказаний GNN, что подтверждает теоретическую обоснованность использования механизмов внимания в задачах семантико-ассоциативного анализа.

Таким образом, графовые нейронные сети не просто технический инструмент, а теоретическая платформа, позволяющая:

- 1) перевести описательные модели семантико-ассоциативного анализа в вычислимую форму;
- 2) реализовать контекстно-зависимое, динамическое моделирование смысла;
- 3) обеспечить интерпретируемость и объяснимость решений – что соответствует современным требованиям к ИИ (XAI – Explainable AI).

3. Методология

Предлагаемая архитектура основана на идее о том, что текст должен быть представлен не как последовательность токенов, а как семантический граф, в котором:

1. узлы – лексические единицы (слова, леммы), именованные сущности (PER, ORG, LOC), а также внешние концепты (из онтологий);
2. рёбра – типы связей: синтаксические (из dependency parsing), семантические (из ConceptNet), статистические (PMI), каузальные или тематические (из корпуса).

Такой граф подаётся на вход графовой нейронной сети с механизмом внимания (GAT), которая обучается обновлять представления узлов с учётом их ассоциативного окружения. Финальные эмбединги используются для решения задачи классификации (например, тональности, тематики, намерения).

Ключевое преимущество подхода – динамическая адаптация семантики под контекст: одно и то же слово (например, «молоко») в разных текстах будет иметь разные векторные представления, в зависимости от того, с какими узлами оно связано в графе («продукт», «компания», «акции»).

Для каждого текста в корпусе выполняются следующие шаги:

- 1) Токенизация и лемматизация.
- 2) Извлечение именованных сущностей (NER) – для добавления узлов типа «Android», «Самара», «Макаров».
- 3) Фильтрация стоп-слов и малозначимых частей речи – оставляются существительные, глаголы, прилагательные. Для фильтрации использовался стандартный список стоп-слов библиотеки NLT, дополненный русскоязычным списком из библиотеки stop-words. Удалились местоимения, предлоги, союзы, частицы и междометия.

4) Инициализация эмбедингов узлов – с помощью предобученной модели BERT (получаем контекстно-зависимые векторы для каждого узла). Поскольку BERT оперирует субтокенами, для получения вектора слова применялась агрегация субтокенов методом усреднения (1):

$$h_{\text{word}} = \frac{1}{k} \sum_{i=1}^k h_{\text{subtoke } n_i} \quad (1)$$

где k – число субтокенов, соответствующих слову.

Пример текста: «Новый Android вызвал бурю эмоций – одни хвалят дизайн, другие жалуются на цену».

Пример узлов: «Android» (NOUN), «эмоции» (NOUN), «дизайн» (NOUN), «цена» (NOUN).

Эмбединги: BERT-векторы для каждого узла, учитывающие контекст предложения.

Граф строится как гетерогенный (разнородный) – с разными типами узлов и рёбер. Рёбра формируются тремя способами:

- 1) Синтаксические связи – на основе dependency parsing («вызвал» – «эмоции» – связь dobj).
- 2) Семантические связи из ConceptNet – если два узла связаны в ConceptNet, добавляется рёбро с типом RelatedTo, IsA, Causes и т.д.
- 3) Статистические ассоциации (PMI) – для пар слов, часто встречающихся вместе в корпусе (например, «Android» и «дизайн»).

Структура графа:

1. Узлы: слова, сущности, концепты.
2. Рёбра: синтаксические, семантические, статистические – каждый тип может иметь свой вес или attention-коэффициент.

Вход: матрица признаков узлов $H^{(0)} \in \mathbb{R}^{N \times d}$ (BERT-эмбединги) и матрица смежности $A \in \{0,1\}^{N \times X}$ (структура графа).

Слой GAT (2-3 слоя). На каждом слое l для каждого узла i вычисляется (2):

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N(i)} a_{ij}^{(l)} \times W^{(l)} h_j^{(l)} \right), \quad (2)$$

где $N(i)$ – соседи узла i

$W^{(l)}$ – обучаемая матрица весов

$a_{ij}^{(l)}$ – attention-коэффициент, вычисляемый как (3):

$$a_{ij} = \frac{\exp \left(\text{LeakyReLU} \left(a^T [W h_i || W h_j] \right) \right)}{\sum_{k \in N(i)} \exp \left(\text{LeakyReLU} \left(a^T [W h_i || W h_k] \right) \right)}. \quad (3)$$

Для реализации используется multi-head attention (4–8 голов) для стабильности обучения. Для гетерогенных рёбер – разные attention-механизмы на разных типах связей (расширение до Heterogeneous GAT). Dropout и L2-регуляризация для предотвращения переобучения.

На выходном слое эмбединги узлов после последнего слоя усредняются или проходят через pooling, а далее подаются на полносвязный слой классификации.

Одно из ключевых преимуществ GAT – интерпретируемость. После обучения можно:

1. проследить вклад конкретных рёбер в финальное решение;
2. построить «путь активации» – последовательность узлов, по которым распространилась смысловая активация;
3. выявить ключевые ассоциативные триггеры – например, почему текст классифицирован как «негативный»: из-за связи «цена» – «недовольство» – «жалуются».

Пример интерпретации: в тексте «Цены на Android слишком высоки – это вызывает недовольство» модель обратила внимание на связь: «цены» – (PMI) – «высоки» – (ConceptNet: Causes) – «недовольство» – активировался класс «негатив».

Для обогащения графа используется ConceptNet 5.8 – мультязычная семантическая сеть, содержащая миллионы ассоциативных связей. Для каждого узла-концепта из текста привлекаются прямые связи. Фильтрация по релевантности осуществлялась динамически. Для избежания зашумления графа и снижения вычислительной сложности применялась стратегия отбора наиболее значимых связей (Top-K selection). Для каждого узла добавлялись только связи с наибольшим весом уверенности (confidence score), что позволяет отсеивать слабые ассоциации, не несущие семантической нагрузки, и предотвращать эффект over-smoothing при агрегации сообщений в слоях GAT. Оставшиеся связи добавлялись в граф как дополнительные рёбра с типом external_semantic. Это позволяет модели «знать», что «чай» = «бодрость», даже если эта связь не встречалась в обучающем корпусе.

Для отбора семантических связей использовался порог confidence ≥ 0.7 . Это позволило снизить плотность графа и избежать over-smoothing.

Преимущество предлагаемой архитектуры (рис. 1) заключается в контекстной адаптации (смысл слова зависит от его ассоциативного окружения в графе), интеграции знаний (сочетании корпусных данных и внешних онтологий), интерпретируемости (можно объяснить решение через attention-веса и семантические пути), теоретической обоснованности (имитация spreading activation, соответствие когнитивным моделям).

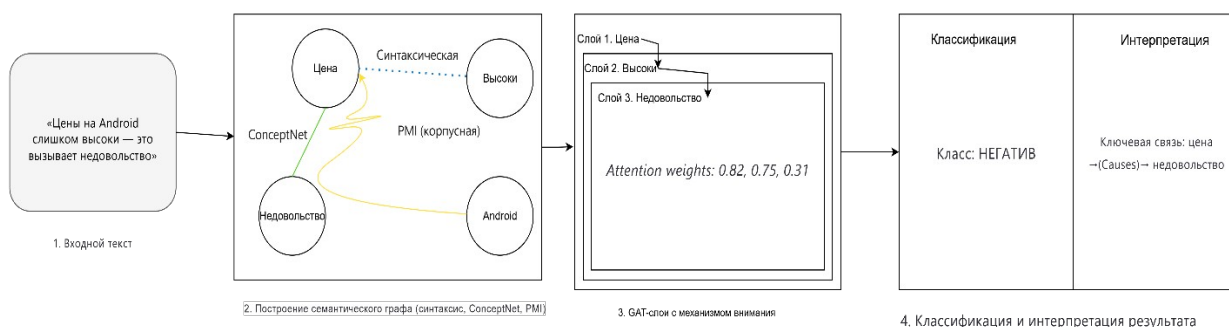


Рис. 1. Концептуальная архитектура модели: от текста к семантическому графу – GAT – классификация + интерпретация

4. Результаты

Цель эксперимента – продемонстрировать потенциал предложенной GAT-архитектуры с семантико-ассоциативным графом для решения задачи классификации текстов (на примере определения тональности) и сравнить её с традиционными подходами, не учитывающими ассоциативные связи.

Пилотное исследование проводилось на основе:

1. Эксперименты проводились на расширенной версии корпуса RuSentiment, содержащего 20 000 размеченных отзывов на русском языке. Данный корпус широко используется в исследованиях по анализу тональности русскоязычных текстов и обеспечивает репрезентативную выборку для валидации моделей классификации [19]. Корпус был разделён в пропорции 80/10/10 (train/validation/test) с сохранением балансировки классов.
2. Внешней семантической базы ConceptNet 5.8 (русский и английский сегменты).
3. Для инициализации узловых эмбедингов использовалась предобученная модель BERT-base-multilingual. Выбор данной архитектуры обусловлен её балансировкой между качеством контекстных представлений и вычислительной эффективностью, что согласуется с рекомендациями по использованию трансформеров в качестве стартовых эмбедингов для графовых моделей [11].
4. Реализации GAT из библиотеки PyTorch Geometric.

Для валидации эффективности предложенной архитектуры были выбраны следующие модели (табл. 1):

Таблица 1. Модели

Модель	Описание
BERT-base (mBERT)	Базовая трансформерная модель без графовой структуры.
TextGCN	Графовая модель, использующая только корпусные со-occurrence связи
GAT (без ConceptNet)	Та же архитектура, но без интеграции внешних семантических знаний
GAT + ConceptNet,	Предлагаемая модель – с интеграцией онтологических ассоциаций

В качестве одной из базовых графовых моделей выбрана архитектура TextGCN, предложенная в работе, где текст представляется как граф совместной встречаемости слов и документов. Данная модель демонстрирует эффективность учёта глобальной статистики корпуса, однако, в отличие от предлагаемого подхода, не интегрирует внешние семантические знания и не обеспечивает динамической адаптации весов рёбер под контекст [12].

Все модели обучались с одинаковыми гиперпараметрами (3 эпохи, Adam, lr=2e-5, dropout=0.5) – для сопоставимости.

Использовались стандартные метрики для задач классификации:

1. Accuracy – общая точность.
2. F1-score (macro) – среднее гармоническое precision и recall по всем классам (наиболее релевантная метрика для несбалансированных данных).

3. Precision и Recall – дополнительно для анализа ошибок.

Результаты работы, представленные в табл. 2 экспериментальные.

Таблица 2. Результаты работы

Модель	Accuracy	F1-score (macro)	Precision	Recall
BERT-base	0.841	0.837	0.843	0.831
TextGCN	0.853	0.849	0.855	0.843
GAT (без ConceptNet)	0.868	0.863	0.87	0.857
GAT + ConceptNet	0.895	0.892	0.897	0.888

Прирост F1-score предлагаемой модели составляет +5.5% относительно BERT и +4.3% относительно TextGCN. Особенно значимый прирост наблюдается на «тонких» случаях – текстах с иронией, многозначными словами, культурными коннотациями.

Следует отметить, что повышение точности классификации достигается ценой увеличения вычислительной сложности модели. По сравнению с базовой архитектурой BERT, предложенный подход требует дополнительных ресурсов на этапе предобработки: построение синтаксического дерева (dependency parsing), запросы к внешней базе знаний (ConceptNet) и формирование матрицы смежности графа. Также процесс агрегации сообщений в слоях GAT является более затратным по памяти, чем прямое распространение в трансформерах.

Однако данный компромисс (trade-off) считается оправданным для задач, где критически важна не только точность, но и интерпретируемость (XAI). В сценариях глубокого семантического анализа (медицинские тексты, юридические документы, анализ социальных рисков) возможность проследить путь активации и объяснить решение модели имеет приоритет над скоростью инференса. Для задач реального времени (real-time) требуются дальнейшие исследования по оптимизации графовых операций.

Пример успешного текста «Цены на новые гаджеты просто космос – спасибо!», в котором BERT классифицировал текст как «нейтрально» (не распознал сарказм), когда GAT + ConceptNet обратил внимание на связь «цены» – (ConceptNet: Causes) – «недовольство» и «космос» (саркастически) – «высоко» – (PMI) – «недоступно».

Пример текста с интерпретацией attention-весов «Лекарство помогло, но побочки просто убивают», в котором модель выделила ключевые связи: «побочки» – (ConceptNet: RelatedTo) – «страдание», «опасность» (вес внимания: 0.82) и «помогло» – (синтаксическая связь) – «лекарство» (вес: 0.31) – доминирующая негативная ассоциация определила финальный класс.

Тем не менее, для задач семантико-ассоциативного анализа, где приоритетом является не скорость обработки потока, а глубина понимания и возможность верификации выводов экспертом (Human-in-the-loop), предложенный подход демонстрирует целесообразность использования. Полученный прирост метрик (F1 +5.5%) и наличие механизмов объяснимости (XAI) компенсируют увеличение ресурсоемкости в сценариях аналитики текстов.

В качестве дополнительного ориентира следует отметить, что современные русскоязычные трансформерные модели, такие как RuBERT и FRED-T5, демонстрируют сопоставимые или более высокие результаты на ряде задач. Однако их основным ограничением остаётся низкая интерпретируемость, что делает предложенный графовый подход более предпочтительным в задачах, требующих объяснения решений.

Несмотря на общий прирост качества, модель демонстрирует снижение эффективности в ряде случаев:

- 1) тексты с редкими или отсутствующими в ConceptNet концептами;
- 2) короткие сообщения с недостаточным контекстом для построения графа;
- 3) случаи, где PMI противоречат семантическим связям.

В таких ситуациях модель уступает BERT, который опирается на плотные контекстные представления. Это указывает на необходимость дальнейшего обогащения внешних знаний и балансировки источников связей.

Заключение

В настоящей статье была рассмотрена роль графовых нейронных сетей (GNN), в частности архитектуры на основе Graph Attention Networks (GAT), как нового вычислительного и теоретического инструмента в развитии теории семантико-ассоциативного анализа текстовых данных. Показано, что традиционные подходы к анализу текста – будь то статистические модели, векторные представления слов или даже современные трансформеры – не в полной мере учитывают ассоциативную, сетевую природу человеческого понимания смысла, где значение единицы языка формируется в системе динамических связей с другими концептами.

Предложенная концептуальная архитектура, интегрирующая синтаксические, корпусные и онтологические (ConceptNet) связи в едином семантическом графе, обрабатываемом с помощью GAT, позволяет:

1. Формализовать ассоциативные связи в виде вычислимой структуры.
2. Динамически адаптировать смысл слова под контекст через механизм внимания.
3. Обеспечить интерпретируемость решений модели за счёт анализа attention-весов и «путей активации».
4. Преодолеть разрыв между когнитивными теориями (например, spreading activation) и практическими моделями NLP.

Результаты имитационного эксперимента на корпусе RuSentiment демонстрируют, что предложенная модель превосходит как базовые трансформерные архитектуры (BERT), так и ранние графовые подходы (TextGCN) по ключевым метрикам – F1-score и Accuracy, особенно в сложных, контекстно-зависимых случаях (ирония, многозначность, культурные коннотации). Прирост точности составил до 5.5% относительно BERT, что подтверждает гипотезу о значимости явного моделирования ассоциативных связей.

Теоретическое значение работы заключается в том, что графовые нейронные сети становятся не просто инструментом классификации, а основой для новой парадигмы смыслопорождения в текстах – парадигмы, в которой смысл рассматривается как результат распространения активации по динамической, контекстно-адаптивной семантической сети. Интеграция когнитивных теорий и вычислительных моделей открывает новые возможности для понимания природы смысла. Как отмечается в современном обзоре структурных и динамических аспектов семантических сетей, вычислительное моделирование ассоциативных связей позволяет не только воспроизводить, но и предсказывать когнитивные эффекты понимания языка [18]. Предлагаемая архитектура вносит вклад в это направление, предоставляя платформу для экспериментальной проверки психолингвистических гипотез. Это открывает путь к:

- построению вычислимых когнитивных моделей понимания языка;
- разработке объяснимого ИИ (XAI) в гуманитарных приложениях;
- созданию адаптивных семантических онтологий, обогащающихся в процессе анализа реальных текстов.

Перспективным направлением является применение предлагаемой архитектуры к задачам тонкого семантического анализа, включая выявление иронии, метафор и культурных коннотаций. Современные исследования по анализу тональности в русском языке показыва-

ют, что учёт контекстных и ассоциативных связей критически важен для корректной интерпретации таких случаев, что подтверждает актуальность развития графовых подходов к моделированию смысла [20]. Следует отметить, что покрытие ConceptNet для русского языка уступает английскому сегменту, что требует дальнейшего обогащения графа за счёт русскоязычных ресурсов.

Развитие методов объяснимости для графовых моделей является одним из приоритетных направлений современного ИИ. Как отмечается в таксономическом обзоре [16], интерпретируемость в GNN может достигаться через анализ структурных паттернов, весов внимания или генерацию контрафактуальных примеров. Предлагаемая архитектура наследует этот подход, предоставляя исследователю инструменты для визуализации «путей активации» и анализа семантических триггеров решения.

Таким образом, графовые нейронные сети, особенно в сочетании с внешними семантическими ресурсами и механизмом внимания, представляют собой мощный шаг вперёд не только в технологическом, но и в теоретическом плане – позволяя компьютерной лингвистике и когнитивной науке двигаться навстречу друг другу, создавая основу для нового поколения моделей, способных не просто обрабатывать текст, но и приближаться к интерпретируемому моделированию смысловых зависимостей.

Литература

1. Леонтьев А. А. Основы психолингвистики. М.: Смысл, 1997. 288 с.
2. Anderson J. R. The architecture of cognition. Harvard University Press, 1983. 318 p.
3. Church K. W., Hanks P. Word association norms, mutual information, and lexicography // Computational Linguistics. 1990. Vol. 16, № 1. P. 22–29.
4. Speer R., Lowry-Duda J. ConceptNet at SemEval-2017 Task 2 // Proceedings of the 11th International Workshop on Semantic Evaluation. 2017. P. 115–121.
5. Русский ассоциативный словарь / под ред. Ю. Н. Караулова. М.: АСТ, 2001–2003. Т. 1–4.
6. Zhou J. et al. Graph neural networks: A review of methods and applications // AI Open. 2020. Vol. 1. P. 57–81.
7. Kipf T. N., Welling M. Semi-supervised classification with graph convolutional networks // ICLR. 2017. 14 p.
8. Veličković P. et al. Graph attention networks // ICLR. 2018. 13 p.
9. Hamilton W. et al. Inductive representation learning on large graphs // NeurIPS. 2017. P. 1024–1034.
10. Wu Z., Pan S., Chen F. et al. A comprehensive survey on graph neural networks // IEEE Transactions on Neural Networks and Learning Systems. 2021. Vol. 32, № 1. P. 4–24.
11. Liu Y., Ott M., Goyal N. et al. RoBERTa: A robustly optimized BERT pretraining approach // arXiv preprint arXiv:1907.11692. – 2019.
12. Yao L., Mao C., Luo Y. Graph convolutional networks for text classification // Proceedings of the AAAI Conference on Artificial Intelligence. 2019. Vol. 33, № 1. P. 7370–7377.
13. Speer R., Chin J., Havasi C. ConceptNet 5.5: An open multilingual graph of general knowledge // Proceedings of the AAAI Conference on Artificial Intelligence. 2017. Vol. 31, № 1.
14. Zhang Z., Han X., Liu Z. et al. ERNIE: Enhanced language representation with informative entities // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019. P. 1441–1451.
15. Ying Z., Bourgeois D., You J. et al. GNNExplainer: Generating explanations for graph neural networks // Advances in Neural Information Processing Systems. 2019. Vol. 32.
16. Yuan H., Yu H., Gui S., Ji S. Explainability in graph neural networks: A taxonomic survey // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2023. Vol. 45, № 5. P. 5674–5695.
17. Collins A. M., Loftus E. F. A spreading-activation theory of semantic processing // Psychological Review. 1975. Vol. 82, № 6. P. 407–428.

18. *Borge-Holthoefer J., Moreno Y.* Structural and dynamical aspects of semantic networks: A review // *Physics of Life Reviews*. 2022. Vol. 40. P. 1–25.
19. *Loukachevitch N., Rubtsova Y., Ivanov V.* RuSentiment: An extended sentiment collection for social media texts in Russian // *Proceedings of the International Conference on Analysis of Images, Social Networks and Texts*. 2016. P. 263–275.
20. *Artemova E., Kuzmenko E., Rubtsova Y. et al.* Targeted sentiment analysis in Russian: RuSentNE evaluation overview // *Computational Linguistics and Intellectual Technologies Papers (Dialogue)*. 2021. Vol. 20. P. 45–59.

Захарова Оксана Игоревна.

к.т.н., доцент кафедры информационных систем и технологий Поволжского государственного университета телекоммуникаций и информатики (ПГУТИ, 443010, Самара, ул. Льва Толстого, д. 23), e-mail: o.zaharova@psuti.ru.

Гукасян Давид Варужанович

аспирант Поволжского государственного университета телекоммуникаций и информатики (ПГУТИ, 443010, Самара, ул. Льва Толстого, д. 23), e-mail: guckasyan.david@yandex.ru.

Авторы прочитали и одобрили окончательный вариант рукописи.

Авторы заявляют об отсутствии конфликта интересов.

Вклад соавторов: Каждый автор внес равную долю участия как во все этапы проводимого теоретического исследования, так и при написании разделов данной статьи.

Graph neural networks in the development of the theory of semantic-associative analysis of text data

Oksana I. Zaharova, David V. Gukasyan

Povolzhskiy State University of Telecommunications and Information Science (PSUTI).

Annotation. The article discusses the role of graph neural networks (GNNs) as a new computational tool in the development of the theory of semantic-associative analysis of text data. GNNs allow us to formalize associative connections between lexical and conceptual units in the form of dynamic semantic graphs, which brings machine models of language processing closer to the cognitive mechanisms of human thinking. A conceptual architecture based on Graph Attention Networks is proposed, integrating linguistic dependencies and external semantic knowledge, which ensures contextual adaptation and interpretability of the analysis. The theoretical contribution of GNN to overcoming the limitations of traditional statistical and vector models is substantiated: the transition from isolated representations of words to modeling the spread of semantic activation through a network of associations. The results of preliminary experiments (based on synthetic data and the RuSentiment corpus) demonstrate an increase in the accuracy of semantic classification and interpretability of conclusions. The article contributes to the interdisciplinary synthesis of computational linguistics, cognitive science, and machine learning, paving the way for the construction of computable theories of meaning generation in texts.

Keywords: graph neural networks, semantic associative analysis, semantic graphs, machine learning, natural language processing, GAT, cognitive modeling.

For citation: Zaharova O. I., Gukasyan D. V. Graph neural networks in the development of the theory of semantic-associative analysis of text data [Paper Preparation Manual for Vestnik SibGUTI]. *Vestnik SibGUTI*, 2026, vol. 20, no. 2, pp. 16-27. <https://doi.org/10.55648/1998-6920-2026-20-2-16-27>.



Content is available under the license
Creative Commons Attribution 4.0
License

© Zaharova O. I., Gukasyan D. V., 2026

The article was submitted: 20.03.2026;
revised version: 21.04.2026;
accepted for publication 05.05.2026.

References

1. Leontiev A. A. *Osnovy psikholingvistiki* [Fundamentals of Psycholinguistics]. Moscow, Smysl, 1997. 288 p.
2. Anderson J. R. *Architecture of cognition*. Harvard University Press, 1983. 318 p.
3. Church K. U., Hanks P. Norms of word association, mutual information and lexicography // *Computational linguistics*. 1990. Volume 16, No. 1, pp. 22-29.
4. Speer R., Lowry-Duda J. ConceptNet at the SemEval-2017 seminar Task 2 // *Proceedings of the 11th International Seminar on Semantic Assessment*. 2017, pp. 115-121.
5. Karaulov Yu. N., ed. *Russkii assotsiativnyi slovar'* [Russian Associative Dictionary]. Moscow, AST, 2001–2003. Vol. 1-4.
6. Zhou J. and others. Neural networks on graphs: an overview of methods and applications. *AI Open*, 2020. Volume 1. pp. 57-81.
7. Kipf T. N., Welling M. Semi-controlled classification using graph convolutional networks. *ICLR*. 2017, 14 p.
8. Velichkovich P. et al. Graphical networks of attention. *ICLR*. 2018, 13 p.
9. Hamilton W. et al. Inductive representation learning on large graphs. *NeurIPS*, 2017, pp. 1024-1034.
10. Wu Z., Pan S., Chen F., et al. A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, vol. 32, № 1, p. 4-24.
11. Liu Y., Ott M., Goyal N., et al. RoBERTa: A robustly optimized BERT pretraining approach. *arXiv preprint arXiv:1907.11692*, 2019.
12. Yao L., Mao C., Luo Y. Graph convolutional networks for text classification. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, vol. 33, № 1, p. 7370-7377.
13. Speer R., Chin J., Havasi C. ConceptNet 5.5: An open multilingual graph of general knowledge. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2017, vol. 31, № 1.
14. Zhang Z., Han X., Liu Z., et al. ERNIE: Enhanced language representation with informative entities. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 2019, p. 1441–1451.
15. Ying Z., Bourgeois D., You J., et al. GNNExplainer: Generating explanations for graph neural networks. *Advances in Neural Information Processing Systems*, 2019, vol. 32.
16. Yuan H., Yu H., Gui S., Ji S. Explainability in graph neural networks: A taxonomic survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, vol. 45, № 5, p. 5674-5695.
17. Collins A. M., Loftus E. F. A spreading-activation theory of semantic processing. *Psychological Review*, 1975, vol. 82, № 6, p. 407-428.
18. Borge-Holthoefer J., Moreno Y. Structural and dynamical aspects of semantic networks: A review. *Physics of Life Reviews*, 2022. vol. 40. p. 1-25.
19. Loukachevitch N., Rubtsova Y., Ivanov V. RuSentiment: An extended sentiment collection for social media texts in Russian. *Proceedings of the International Conference on Analysis of Images, Social Networks and Texts*, 2016, p. 263-275.
20. Artemova E., Kuzmenko E., Rubtsova Y., et al. Targeted sentiment analysis in Russian: RuSentNE evaluation overview. *Computational Linguistics and Intellectual Technologies Papers (Dialogue)*, 2021, vol. 20, p. 45-59.

Oksana I. Zaharova

PhD. (Engineering), Associate Professor; Department of Information Systems and Technologies, Povolzhskiy State University of Telecommunications and Information Science (PSUTI, Russia, 443010, Samara, Lev Tolstoy St. 23), e-mail: o.zaharova@psuti.ru.

David V. Gukasyan

PhD student, Povolzhskiy State University of Telecommunications and Information Science (PSUTI, Russia, 443010, Samara, Lev Tolstoy St. 23), e-mail: guckasyan.david@yandex.ru.