

О.С. Салыкова^{1*}, А.А. Артыкбаева¹, А.М. Исакова¹, Л.И. Нурмагамбетова²

¹Костанайский региональный университет имени Ахмет Байтұрсынұлы,
110000, Республика Казахстан, г. Костанай, ул. А. Байтұрсынова, 47

²Костанайский инженерно-экономический университет имени Мыржакыпа Дулатова,
110000, Республика Казахстан, г. Костанай, ул. Чернышевского, 59

*e-mail: solga0603@mail.ru

НЕЙРОСЕТЕВЫЕ МЕТОДЫ АНАЛИЗА ТЕКСТОВЫХ ОТЗЫВОВ ОБУЧАЮЩИХСЯ: АРХИТЕКТУРА, ОБУЧЕНИЕ И ИНТЕРПРЕТАЦИЯ РЕЗУЛЬТАТОВ

Аннотация: В статье представлен сравнительный анализ нейросетевых архитектур LSTM, BiLSTM и RuBERT, применяемых для автоматической классификации студенческих отзывов. Особое внимание уделено задачам предобработки данных, ручной разметки с учётом эмоциональной окраски и тематических аспектов, а также оценке надёжности корпуса с использованием коэффициента согласия Cohen's kappa (0,82). Экспериментальные результаты показали, что RuBERT обеспечивает наивысшие значения Accuracy (0,87) и F1-score (0,85), что статистически подтверждено результатами t-теста. В то же время BiLSTM продемонстрировала более высокую эффективность по сравнению с LSTM благодаря учёту контекста в обеих направлениях. Проведённый анализ ошибок показал, что рекуррентные модели чаще всего путают нейтральные и отрицательные отзывы, а трансформерная архитектура лучше справляется с обработкой двусмысленных формулировок и скрытых эмоциональных оттенков. Практическая значимость исследования заключается в возможности интеграции разработанного подхода в системы LMS и цифровые образовательные платформы для автоматизации анализа обратной связи студентов. В качестве перспективных направлений обозначены расширение корпуса за счёт казахоязычных текстов и использование современных моделей семейства Transformer (RoBERTa, DeBERTa, ChatGLM).

Ключевые слова: нейросетевой анализ текста, образовательная аналитика, BERT, LSTM, автоматическая классификация, обработка текстов, обратная связь студентов, интеллектуальные системы образования.

Введение

Обратная связь обучающихся играет важную роль в оценке качества образования, методов преподавания и удовлетворённости студентов учебным процессом [1]. С развитием цифровых платформ объём поступающих отзывов стремительно увеличивается, что делает их ручной анализ трудоёмким и недостаточно объективным. В этих условиях актуально использование современных методов обработки естественного языка и нейросетевых технологий, позволяющих автоматизировать анализ обратной связи и получать воспроизводимые результаты.

Ранние подходы основывались на простых статистических признаках (TF-IDF, Bag-of-Words, [2]) и классических алгоритмах машинного обучения (наивный байесовский классификатор, SVM [3], логистическая регрессия). Эти методы отличались простотой и интерпретируемостью, но показывали ограниченную эффективность при работе с короткими и семантически близкими высказываниями.

Существенный прогресс был достигнут благодаря нейросетевым архитектурам, включая LSTM [4], BiLSTM [5] и модели на базе Transformer, такие как BERT [6], RoBERTa [7], DistilBERT. Данные решения обеспечивают учёт контекста в обеих направлениях, высокую точность и переносимость между задачами, открывая новые возможности для анализа образовательных текстов – отзывов и комментариев студентов (включая анкеты и сообщения в онлайн-курсах). Эти данные являются важным источником информации о качестве образования и эффективности учебного процесса. Однако ручная обработка подобных массивов трудоёмка и субъективна, что делает актуальным применение методов автоматизированного анализа текста и нейросетевых технологий [8], [9].

Цель исследования – разработка и сравнительный анализ нейросетевых архитектур для автоматической классификации и интерпретации студенческих отзывов. Для её достижения решаются задачи: формирование корпуса отзывов и его предобработка; ручная

разметка данных по эмоциональным и тематическим признакам; обучение и тестирование моделей LSTM, BiLSTM и BERT; оценка качества классификации с использованием стандартных метрик; анализ возможностей интеграции моделей в информационные системы вуза.

Научная новизна исследования заключается в том, что впервые проведён систематический сравнительный анализ архитектур LSTM, BiLSTM и RuBERT на корпусе реальных студенческих отзывов вузов Казахстана. В отличие от многочисленных зарубежных работ, где основной акцент сделан на англоязычных образовательных текстах, данное исследование ориентировано на русскоязычные данные, что позволяет учитывать национальные и языковые особенности. Вклад работы состоит в демонстрации воспроизводимости результатов, выявлении закономерностей ошибок различных моделей и показе практических возможностей интеграции RuBERT в LMS и цифровые образовательные платформы.

Методы исследования

В ходе настоящей работы была разработана и реализована система для анализа текстовых отзывов обучающихся с использованием нейросетевых моделей классификации. Основу корпуса составили анонимные комментарии студентов, собранные в рамках внутреннего мониторинга образовательного процесса в университете.

Предобработка текстов включала приведение к нижнему регистру, удаление знаков препинания, токенизацию, исключение стоп-слов, а также лемматизацию с применением инструментов NLTK и SpaCy. Для LSTM и BiLSTM использовалась векторизация Word2Vec с размерностью 300, обученная на корпусе студенческих отзывов. Такой подход позволил учитывать семантическую близость слов, что особенно важно для коротких фраз и эмоционально окрашенных выражений.

Ручная разметка данных осуществлялась тремя независимыми аннотаторами – преподавателями и аспирантами кафедры программного обеспечения. Каждый отзыв маркировался по двум критериям: эмоциональная окраска (положительный, нейтральный или отрицательный характер высказывания); тематика высказывания (содержание курса, методика преподавания, организационные аспекты).

В итоговом корпусе 38% отзывов были положительными, 34% – нейтральными и 28% – отрицательными. Для повышения надёжности данных применялась процедура двойной разметки: часть отзывов размечалась перекрёстно двумя экспертами. Согласованность между аннотаторами оценивалась с использованием коэффициента Cohen's kappa, который составил 0,82, что указывает на высокий уровень согласия и подтверждает воспроизводимость базы данных.

В качестве основной архитектуры использовалась предобученная модель BERT-base (uncased), разработанная Google Research [6]. Однако с учётом языковой специфики корпуса применялась также русскоязычная модель RuBERT, созданная на базе архитектуры BERT и обученная на текстах на русском языке. Модель была загружена из открытого репозитория DeepPavlov и использовалась с параметрами: размер батча – 32, количество эпох – 5, функция потерь – categorical crossentropy.

Для моделирования и классификации текстов были выбраны три типа нейросетевых моделей, широко применяемых в задачах обработки естественного языка: LSTM (Long Short-Term Memory) – базовая модель, учитывающая последовательность слов и сохраняющая долгосрочные зависимости; BiLSTM – модификация LSTM, обеспечивающая двунаправленную обработку текста и позволяющая учитывать контекст как слева, так и справа; BERT (Bidirectional Encoder Representations from Transformers) – современная трансформерная архитектура, продемонстрировавшая высокую эффективность на широком спектре задач NLP (рис. 1).



Рисунок 1 – Архитектура обработки текстового отзыва: от предобработки до классификации

Для обучения моделей использовались популярные фреймворки машинного обучения – TensorFlow и PyTorch. Гиперпараметры для каждой архитектуры подбирались с учётом особенностей корпуса и задачи классификации. Все параметры приведены в таблице 1, что обеспечивает воспроизводимость и возможность повторения эксперимента.

Таблица 1 – Гиперпараметры обученных моделей

Параметр	LSTM	BiLSTM	BERT (RuBERT)
Тип модели	LSTM	BiLSTM	RuBERT (DeepPavlov)
Размер батча	32	32	16
Количество эпох	10	10	5
Оптимизатор	Adam	Adam	Adam
Функция потерь	crossentropy	crossentropy	crossentropy
Размер эмбединга	300	300	768 (предобученный)

Анализ используемых параметров показал, что модели LSTM и BiLSTM обучались с одинаковыми настройками, что позволило объективно оценить влияние двунаправленной структуры на качество классификации. В то же время модель BERT (в русскоязычной реализации RuBERT) требовала меньшего числа эпох и использовала более компактный размер батча. Это объясняется тем, что модель уже прошла масштабное предобучение и обладает более информативными представлениями текста. Существенное различие в размере эмбедингов между BERT и рекуррентными сетями подчёркивает архитектурные особенности каждого подхода и их различную способность к извлечению смысловых зависимостей.

Выбор параметров оказал влияние как на скорость обучения, так и на итоговое качество классификации, что отражено в метриках, представленных в последующих разделах. В качестве функции потерь была использована categorical crossentropy, а оптимизация осуществлялась с использованием алгоритма Adam. Для оценки качества классификации применялись метрики accuracy, precision, recall и F1-score. Обучение проводилось на тренировочном подмножестве данных (80% корпуса), а тестирование - на валидационной выборке (20%).

Результаты исследований

Для оценки эффективности выбранных архитектур – LSTM, BiLSTM и BERT – был проведён эксперимент на размеченном корпусе студенческих отзывов. Данные были предварительно разделены на обучающую выборку (80% общего объёма) и тестовую (20%), что позволило объективно оценить обобщающую способность моделей.

В ходе эксперимента основное внимание уделялось следующим метрикам: Accuracy – общая точность классификации; F1-score – сбалансированная метрика, учитывающая как полноту, так и точность; Recall – показатель полноты, отражающий способность модели выявлять целевые категории.

Результаты сравнительного анализа приведены в таблице 2 и проиллюстрированы на рисунке 2.

Таблица 2 – Результаты классификации моделей (Accuracy, Recall, F1-score)

Модель	Accuracy	Recall	F1-score
LSTM	0.75	0.70	0.72
BiLSTM	0.81	0.77	0.79
BERT	0.87	0.84	0.85

Для проверки статистической значимости различий между моделями был применён t-тест Стьюдента. Различия между результатами RuBERT и BiLSTM по метрикам Accuracy ($p = 0.032$) и F1-score ($p = 0.027$) оказались статистически значимыми при уровне значимости $p < 0.05$. Это подтверждает, что превосходство трансформерной архитектуры не является случайным, а имеет устойчивый характер.

Анализ показал, что RuBERT продемонстрировал наилучшие показатели по всем метрикам. BiLSTM превзошла LSTM благодаря учёту контекста в обоих направлениях, однако уступила трансформерной архитектуре. LSTM показала наименьшую полноту и F1-score, но её преимуществом остаются меньшие вычислительные затраты.

Дополнительно следует отметить, что модель BERT наиболее уверенно классифицирует положительные и отрицательные отзывы, достигая высокой точности по этим категориям. Для интерпретации работы модели был проведён анализ attention-механизма. При классификации отрицательных отзывов модель фокусировалась на словах «часто», «проблемы», «сбои». Наибольшее количество ошибок связано с нейтральными отзывами, которые нередко содержат двусмысленные или контекстуально сложные формулировки.




Рисунок 2 – Сравнительное качество моделей LSTM, BiLSTM и RuBERT по метрикам Accuracy и F1-score

Из рисунка 2 видно, что RuBERT демонстрирует явное преимущество над рекуррентными моделями.

Анализ ошибок моделей. LSTM нередко неверно классифицировала нейтральные отзывы, относя их к отрицательным. Например, высказывание «Лекции проходят вовремя, но материал даётся быстро» модель интерпретировала как отрицательное из-за наличия слов «быстро» и «но», хотя по смыслу отзыв скорее нейтральный. BiLSTM продемонстрировала более высокую точность за счёт учёта контекста в обоих направлениях, однако также испытывала трудности с предложениями со скрытой иронией. Так, фраза «Преподаватель всегда старается, жаль, что не всегда получается» была отнесена к положительным, несмотря на явный критический оттенок. Эти примеры подтверждают, что рекуррентные архитектуры склонны ошибаться при обработке двусмысленных формулировок и неявных эмоциональных оттенков, тогда как RuBERT лучше справляется с подобными случаями благодаря более богатому контекстному представлению текста.

Примеры корректно классифицированных отзывов включают фразы: «Преподаватель подробно объясняет материал» – положительный отзыв, отнесённый к категории «качество преподавания»; «В системе часто бывают сбои» – отрицательный отзыв, классифицированный как «технические трудности». В то же время наибольшие трудности для всех моделей вызывали иронические или саркастические формулировки, например: «Если вы любите сюрпризы – приходите на этот курс», ошибочно интерпретированное как положительное.

Анализ confusion matrix (рис. 3) подтверждает, что наибольшее количество ошибок у модели связано с нейтральными отзывами.




Рисунок 3 – Confusion matrix для модели BERT

Это подчёркивает необходимость дальнейшего совершенствования методов интерпретации скрытых смыслов и тональных оттенков текста, включая обработку двусмысленных и саркастических формулировок. Наибольшая часть ошибок связана с путаницей нейтральных и отрицательных отзывов, что согласуется с результатами анализа ошибок рекуррентных моделей

Обсуждение научных результатов

Полученные результаты демонстрируют преимущества трансформерных архитектур в задаче анализа образовательных текстов. Выявленное превосходство RuBERT по сравнению с рекуррентными моделями согласуется с данными зарубежных исследований, где аналогичные выводы были сделаны для RoBERTa и DeBERTa [7, 10]. В частности, работы Zhang и соавт. и Xu и др. [11, 12] показали, что модели на базе трансформеров обеспечивают более высокую устойчивость к контекстуальной неоднозначности, чем LSTM и BiLSTM. Результаты также подтверждают эффективность BiLSTM, которая демонстрирует более высокую точность по сравнению с LSTM. Это связано с учётом контекста в обеих направлениях. Этот вывод согласуется с экспериментами Li и соавт. [13], где аналогичный эффект был зафиксирован при анализе отзывов в образовательной среде. Важно подчеркнуть, что высокая точность RuBERT достигается ценой больших вычислительных затрат. Этот фактор ограничивает возможности его внедрения в условиях университетов, где ресурсы могут быть ограниченными. В отличие от этого, LSTM и BiLSTM обеспечивают более быструю обработку при приемлемом уровне точности, что делает их подходящими для систем, где важна скорость отклика.

Таким образом, проведённое исследование подтверждает устойчивую тенденцию: архитектуры на базе трансформеров становятся основным инструментом анализа текстовых данных, в том числе в образовательной аналитике. Однако в практических условиях выбор модели должен учитывать баланс между качеством классификации и доступными вычислительными ресурсами

Заключение

Проведённое исследование показало эффективность применения нейросетевых моделей для анализа текстовых отзывов обучающихся. Сравнение архитектур LSTM, BiLSTM и RuBERT подтвердило преимущество трансформерных решений: модель RuBERT обеспечила наивысшие показатели Accurasy, Recall и F1-score, что статистически подтверждено результатами t-теста.

Научная новизна работы заключается в систематическом сравнительном анализе рекуррентных и трансформерных архитектур именно на корпусе студенческих отзывов вузов Казахстана. Это позволило продемонстрировать воспроизводимость экспериментов, выявить закономерности ошибок различных моделей и обосновать возможность интеграции RuBERT в системы LMS и цифровые образовательные платформы.

Практическая значимость исследования состоит в том, что предложенный подход позволяет автоматизировать обработку обратной связи студентов, повышая объективность оценки качества образовательного процесса и снижая трудозатраты преподавателей и администрации вузов.

Ограничения исследования связаны с использованием одного корпуса данных и фокусом на русскоязычных текстах. Перспективным направлением является расширение базы за счёт казахоязычных отзывов обучающихся, а также включение многоязычных коллекций. Это создаст основу для разработки двуязычных и многоязычных систем образовательной аналитики.

Таким образом, результаты работы демонстрируют высокий потенциал нейросетевых архитектур в образовательной аналитике и формируют базу для дальнейших исследований с использованием современных моделей (RoBERTa, DeBERTa, ChatGLM) и методов интерпретации (attention-механизмы, визуализация признаков).

Список литературы

1. Васнецова Е.Л. Применение методов анализа тональности в образовательной среде / Е.Л. Васнецова, Д.А. Семенов // Образовательные технологии и общество. – 2021. – № 24(1). – С.105-116.
2. Efficient estimation of word representations in vector space / T. Mikolov et al // arXiv preprint arXiv:1301.3781, 2013.

3. Cortes C. Support-vector networks / C. Cortes, V. Vapnik // Machine Learning. – 1995. – № 20(3). – P. 273-297.
4. Schuster M.K. Bidirectional recurrent neural networks / M. Schuster, K.K. Paliwal // IEEE Transactions on Signal Processing. – 1997. – № 45(11). – P. 2673-2681.
5. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – № 9(8). – P. 1735-1780.
6. RoBERTa – BiLSTM: A Context – Aware Hybri Model for Sentiment Analysis / Rahman M.M. et al // arXiv preprint arXiv:2406.00367. – 2024. <https://doi.org/10.48550/arXiv.2406.00367>.
7. BERT: Pre-training of deep bidirectional transformers for language understanding / J. Devlin et al // Proceedings of NAACL-HLT. – 2019. – P. 4171-4186.
8. RoBERTa: A robustly optimized BERT pretraining approach / Y. Liu et al // arXiv preprint arXiv:1907. – 2019. – P. 11692.
9. Lin F. Sentiment analysis in online education: An analytical approach and application / F. Lin // Proceedings of the International Conference on Machine Learning and Automation. – 2024.
10. An improved neural network model for sentiment analysis in online education / B. Xu et al // Journal of Intelligent & Fuzzy Systems. – 2020. – № 38(3). – P. 3651-3662.
11. Elevating educational insights: Sentiment analysis of faculty feedback using advanced machine learning models / S.B. Deshpande et al // Advances in Continuous and Discrete Models. – 2025.
12. Zhang W. Comparative evaluation of Transformer-based models for multilingual sentiment analysis / W. Zhang, L. Xu, J. Wang // Journal of Artificial Intelligence Research. – 2024. – № 71. – P. 55-72.
13. Xu R. Advances in DeBERTa for educational text mining / R. Xu, H. Chen, Z. Huang // Computers & Education. – 2025. – № 198. – P. 104719.
14. Li X. Sentiment analysis in educational contexts: Comparing LSTM and BiLSTM approaches / X. Li, Y. Zhang, H. Zhao // Education and Information Technologies. – 2023. – № 28(2). – P. 213-229.

References

1. Vasnetsova E.L. Primenenie metodov analiza tonal'nosti v obrazovatel'noi srede / E.L. Vasnetsova, D.A. Semenov // Obrazovatel'nye tekhnologii i obshchestvo. – 2021. – № 24(1). – S.105-116. (In Russian).
2. Efficient estimation of word representations in vector space / T. Mikolov et al // arXiv preprint arXiv:1301.3781, 2013. (In English).
3. Cortes C. Support-vector networks / C. Cortes, V. Vapnik // Machine Learning. – 1995. – № 20(3). – R. 273-297. (In English).
4. Schuster M.K. Bidirectional recurrent neural networks / M. Schuster, K.K. Paliwal // IEEE Transactions on Signal Processing. – 1997. – № 45(11). – R. 2673-2681. (In English).
5. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – № 9(8). – R. 1735-1780. (In English).
6. RoBERTa – BiLSTM: A Context – Aware Hybri Model for Sentiment Analysis / Rahman M.M. et al // arXiv preprint arXiv:2406.00367. – 2024. <https://doi.org/10.48550/arXiv.2406.00367>. (In English).
7. BERT: Pre-training of deep bidirectional transformers for language understanding / J. Devlin et al // Proceedings of NAACL-HLT. – 2019. – R. 4171-4186. (In English).
8. RoBERTa: A robustly optimized BERT pretraining approach / Y. Liu et al // arXiv preprint arXiv:1907. – 2019. – R. 11692. (In English).
9. Lin F. Sentiment analysis in online education: An analytical approach and application / F. Lin // Proceedings of the International Conference on Machine Learning and Automation. – 2024. (In English).
10. An improved neural network model for sentiment analysis in online education / V. Xu et al // Journal of Intelligent & Fuzzy Systems. – 2020. – № 38(3). – R. 3651-3662. (In English).
11. Elevating educational insights: Sentiment analysis of faculty feedback using advanced machine learning models / S.B. Deshpande et al // Advances in Continuous and Discrete Models. – 2025. (In English).
12. Zhang W. Comparative evaluation of Transformer-based models for multilingual sentiment analysis / W. Zhang, L. Xu, J. Wang // Journal of Artificial Intelligence Research. – 2024. – № 71. – R. 55-72. (In English).

13. Xu R. Advances in DeBERTa for educational text mining / R. Xu, H. Chen, Z. Huang // Computers & Education. – 2025. – № 198. – R. 104719. (In English).
14. Li X. Sentiment analysis in educational contexts: Comparing LSTM and BiLSTM approaches / X. Li, Y. Zhang, H. Zhao // Education and Information Technologies. – 2023. – № 28(2). – R. 213-229. (In English).

О.С. Салыкова^{1*}, А.А. Артыкбаева¹, А.М. Исакова¹, Л.И. Нурмагамбетова²

¹Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті,

110000, Қазақстан Республикасы, Қостанай қ., А. Байтұрсынов көшесі, 47

²Міржақып Дулатов атындағы Қостанай инженерлік-экономикалық университеті

110000, Қазақстан Республикасы, Қостанай қ., Чернышевский көшесі, 59

*e-mail: solga0603@mail.ru

БІЛІМ АЛУШЫЛАРДЫҢ МӘТІНДІК ПІКІРЛЕРІН ТАЛДАУДЫҢ НЕЙРОНДЫҚ ЖЕЛІ ӘДІСТЕРІ: СӘУЛЕТ, ОҚЫТУ ЖӘНЕ НӘТИЖЕЛЕРДІ ТҮСІНДІРУ

Мақалада студенттердің пікірлерін автоматты түрде жіктеу үшін қолданылатын LSTM, BiLSTM және RuBERT нейрожелілік архитектураларының салыстырмалы талдауы ұсынылған. Зерттеуде деректерді алдын ала өңдеуге, эмоционалдық реңк пен тақырыптық аспектілерді ескеріп қолмен белгілеуге, сондай-ақ корпусың сенімділігін Cohen's kappa коэффициенті (0,82) арқылы бағалауға ерекше көңіл бөлінді. Эксперименттік нәтижелер RuBERT моделінің ең жоғары дәлдікке (Accuracy = 0,87) және F1-score = 0,85 көрсеткіштеріне қол жеткізгенін көрсетті, бұл t-тест нәтижелерімен статистикалық тұрғыдан расталды. Сонымен қатар, BiLSTM контексті екі бағытта ескерудің арқасында LSTM-мен салыстырғанда жақсы нәтижелер көрсетті. Қателерді талдау рекуррентті модельдердің бейтарап және теріс пікірлерді жиі шатастыратынын, ал трансформерлік архитектураның екіұшты тұжырымдар мен жасырын эмоциялық реңктерді дәлірек өңдейтінін көрсетті. Зерттеудің практикалық маңыздылығы студенттердің пікірлерін талдауды автоматтандыру үшін әзірленген тәсілді LMS пен цифрлық білім беру платформаларына интеграциялау мүмкіндігінде. Болашақ зерттеулер қазақ тіліндегі мәтіндер корпустарын кеңейтуді және RoBERTa, DeBERTa, ChatGLM сияқты заманауи трансформерлік модельдерді қолдануды қамтиды.

Түйін сөздер: мәтіндік талдау, білім беру аналитикасы, BERT үлгісі, LSTM, автоматты жіктеу, мәтінді өңдеу, студенттердің кері байланысы, интеллектуалды білім беру жүйелері.

O.S. Saltykova^{1*}, A.A. Artykbayeva¹, A.M. Isakova¹, L.I. Nurmagambetova²

¹Kostanay Regional University named after Akhmet Baitursynuly,

110000, Republic of Kazakhstan, Kostanay, 47 A. Baitursynova street

²Kostanay Engineering and Economics University named after Myrzhakyp Dulatov,

110000, Republic of Kazakhstan, Kostanay, 59 Chernyshevsky street

*e-mail: solga0603@mail.ru

NEURAL NETWORK METHODS FOR ANALYZING TEXT FEEDBACK FROM STUDENTS: ARCHITECTURE, LEARNING, AND INTERPRETATION OF RESULTS

This article presents a comparative analysis of neural network architectures LSTM, BiLSTM, and RuBERT applied to the automatic classification of student feedback. Particular attention is paid to data preprocessing, manual annotation with consideration of sentiment and thematic aspects, as well as corpus reliability assessment using Cohen's kappa coefficient (0.82). The experimental results show that RuBERT achieves the highest Accuracy (0.87) and F1-score (0.85), which is statistically confirmed by t-test results. At the same time, BiLSTM demonstrates higher efficiency compared to LSTM due to its ability to capture bidirectional context. Error analysis revealed that recurrent models most often confuse neutral and negative feedback, while the transformer-based architecture performs better in handling ambiguous expressions and subtle emotional nuances. The practical significance of the study lies in the possibility of integrating the proposed approach into LMS and digital educational platforms to automate the analysis of student feedback. Future research directions include expanding the corpus with Kazakh-language texts and applying advanced Transformer-based models (RoBERTa, DeBERTa, ChatGLM).

Key words: neural network text analysis, educational analytics, BERT, LSTM, automatic classification, text preprocessing, student feedback, intelligent educational systems.

Сведения об авторах

Ольга Сергеевна Салыкова* – кандидат технических наук, ассоциированный профессор кафедры «Программного обеспечения», Костанайский региональный университет имени Ахмет Байтұрсынұлы, Республика Казахстан; e-mail: solga0603@mail.ru. ORCID: <https://orcid.org/0000-0002-8681-4552>.

Асель Айдарбековна Артыкбаева – докторант кафедры «Программного обеспечения» Костанайского регионального университета имени Ахмет Байтұрсынұлы, Республика Казахстан; e-mail: asel_aidarbekowna@mail.ru. ORCID: <https://orcid.org/0009-0001-2233-092X>.

Альмира Мухтаровна Исакова – докторант кафедры «Программного обеспечения» Костанайского регионального университета имени Ахмет Байтұрсынұлы, Республика Казахстан; e-mail: n.a.almira.24@gmail.com. ORCID: <https://orcid.org/0009-0000-4288-9774>

Ляйля Искендировна Нурмагамбетова – кандидат экономических наук, ассоциированный профессор ассоциированный профессор кафедры «Социально-экономических дисциплин», Костанайский инженерно-экономический университет имени Мыржақыпа Дулатова, Республика Казахстан; e-mail: Leila0205@mail.ru. ORCID: 0009-0002-4459-5010.

Авторлар туралы мәліметтер

Ольга Сергеевна Салыкова* – техника ғылымдарының кандидаты, «Бағдарламалық қамтамасыз ету» кафедрасының қауымдастырылған профессоры, Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қазақстан Республикасы; e-mail: solga0603@mail.ru. ORCID: <https://orcid.org/0000-0002-8681-4552>.

Асель Айдарбековна Артыкбаева – «Бағдарламалық қамтамасыз ету» кафедрасының докторанты, Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қазақстан Республикасы; e-mail: asel_aidarbekowna@mail.ru. ORCID: <https://orcid.org/0009-0001-2233-092X>.

Альмира Мухтаровна Исакова – «Бағдарламалық қамтамасыз ету» кафедрасының докторанты; Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қазақстан Республикасы; e-mail: n.a.almira.24@gmail.com. ORCID: <https://orcid.org/0009-0000-4288-9774>.

Ляйля Искендировна Нурмагамбетова – экономика ғылымдарының кандидаты, қауымдастырылған профессор «Әлеуметтік – экономикалық пәндер» кафедрасының қауымдастырылған профессоры, Мыржақып Дулатов атындағы Қостанай инженерлік – экономикалық университеті, Қазақстан Республикасы; e-mail: Leila0205@mail.ru. ORCID: <https://orcid.org/0009-0002-4459-5010>.

Information about the authors

Olga Salykova* – candidate of technical sciences, associate professor of the Department of Software Engineering, Kostanay Regional University named after Akhmet Baitursynuly, Republic of Kazakhstan; e-mail: solga0603@mail.ru. ORCID: <https://orcid.org/0000-0002-8681-4552>.

Assel Artykbayeva – doctoral student of the department of Software Engineering, A. Baitursynov Kostanay Regional University, Republic of Kazakhstan; e-mail: asel_aidarbekowna@mail.ru. ORCID: <https://orcid.org/0009-0001-2233-092X>.

Almira Iskakova – doctoral student of the department of Software Engineering, A. Baitursynov Kostanay Regional University, Republic of Kazakhstan; e-mail: n.a.almira.24@gmail.com. ORCID: <https://orcid.org/0009-0000-4288-9774>.

Lyailya Nurmagambetova – candidate of economic sciences, associate professor, associate professor of the Department of Socio-economic disciplines, Kostanay Engineering and Economics University named after Myrzakyp Dulatov, Republic of Kazakhstan; e-mail: Leila0205@mail.ru. ORCID: <https://orcid.org/0009-0002-4459-5010>.

Поступила в редакцию 03.06.2025

Поступила после доработки 08.09.2025

Принята к публикации 16.09.2025

[https://doi.org/10.53360/2788-7995-2025-4\(20\)-4](https://doi.org/10.53360/2788-7995-2025-4(20)-4)

MPHTI: 50.41.23



К.П. Аман, А.А. Мусина*

Актюбинский региональный университет им. К. Жубанова,
030000, Республика Казахстан, г. Актобе, ул. А. Молдагуловой, 34А
*e-mail: alla.mussina@mail.ru

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ПРОИЗВОДИТЕЛЬНОСТИ BGP И OSPF В МУЛЬТИУРОВНЕВЫХ АРХИТЕКТУРАХ

Аннотация: Статья посвящена сравнительному анализу двух основных протоколов маршрутизации - OSPF (Open Shortest Path First) и BGP (Border Gateway Protocol) в мультиуровневых сетевых архитектурах. В ходе работы были проведены тесты с использованием Cisco Packet Tracer для анализа реальной производительности обоих протоколов. Были рассмотрены такие аспекты, как время установления соединения, скорость конвергенции, нагрузка на ресурсы и гибкость политики маршрутизации.