

СРАВНЕНИЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ТОНАЛЬНОСТИ В ЭЛЕКТРОННОМ ОБУЧЕНИИ

Або-Рашед Кнаан

Аспирант, Белгородский государственный
национальный исследовательский университет
Kanan.rashed@gmail.com

Польщиков Константин Александрович

д.т.н., Белгородский государственный национальный
исследовательский университет
polshchikov@bsu.edu.ru

Головко Ярослав Юрьевич

аспирант, Белгородский государственный
национальный исследовательский университет
Golovko.laroslav@gmail.com

COMPARING MACHINE LEARNING MODELS FOR E-LEARNING SENTIMENT ANALYSIS

**Knaan Abo-Rashed
K. Polshchikov
Ia. Golovko**

Summary: Sentiment analysis plays a crucial role in understanding student experiences in e-learning environments. This study examines the comparative effectiveness of four distinct machine learning models — Naive Bayes, Support Vector Machines, Decision Trees, and Random Forests — in sentiment analysis of 3000 tweets related to e-learning. The models' evaluations are based on parameters such as accuracy, recall, specificity, and the F1 score. The ideal model selection should balance factors like computational resources, interpretability, and adaptability. These results offer valuable insights for e-learning platform administrators and teachers, potentially guiding improvements in course content, its delivery, and user experience. The study acknowledges potential limitations related to model bias and the complexity of generalizing conclusions to other e-learning platforms. Future research directions include mitigating bias and enhancing the applicability of these models to various platforms and data sources. This work contributes significantly to the evolving field of applying machine learning in sentiment analysis in e-learning.

Keywords: sentiment analysis, e-learning, machine learning, naive bayes, support vector machines, decision trees, random forest.

Аннотация. Анализ тональности играет ключевую роль в понимании опыта студентов в условиях электронного обучения. Это исследование рассматривает сравнительную эффективность четырех различных моделей машинного обучения — наивного Байеса, метода опорных векторов, деревьев решений и случайного леса — в анализе тональности 3000 твитов, связанных с электронным обучением. Оценка моделей основывается на таких параметрах, как точность, полнота, специфичность и F1-мера. Выбор идеальной модели должен уравнивать такие факторы, как вычислительные ресурсы, интерпретируемость и адаптивность. Эти результаты предлагают ценные выводы для администраторов платформ электронного обучения и преподавателей, потенциально направляя улучшения содержания курса, его проведения и пользовательского опыта. Исследование признает потенциальные ограничения, связанные с предвзятостью модели и сложностью обобщения выводов на другие платформы электронного обучения. Направления будущих исследований включают смягчение предвзятости и улучшение применимости этих моделей к различным платформам и источникам данных. Эта работа вносит существенный вклад в развивающуюся область применения машинного обучения в анализе тональности в электронном обучении.

Ключевые слова: анализ тональности текста, электронное обучение, машинное обучение, наивный Байес, метод опорных векторов, деревья решений, случайный лес.

Введение

Анализ тональности, также известный как извлечение мнений или эмоциональный искусственный интеллект, это техника обработки естественного языка, которая направлена на идентификацию, извлечение и количественную оценку субъективной информации из текстовых данных [3]. В контексте электронного обучения анализ тональности стал жизненно важным инструментом для понимания эмоций и мнений студентов о платформах онлайн-обучения, учебных материалах и методах преподавания [1]. С быстрым расширением систем электронного обучения и увеличением числа студентов, участвующих в онлайн-образовании, анализ их чувств стал необходимым для улучшения их опыта обучения и общего удовлетворения [5].

Эмоции студентов играют важную роль в их учебном опыте, влияя на мотивацию, вовлеченность и академическую успеваемость. В условиях электронного обучения понимание эмоций студентов особенно важно, поскольку онлайн-платформы часто не имеют прямого общения лицом к лицу, что затрудняет оценку настроений студентов преподавателями и администраторами. Анализ тональности предлагает подход на основе данных для оценки эмоций студентов, позволяя заинтересованным сторонам определить области улучшения, адаптировать стратегии обучения и предложить индивидуальную поддержку на основе эмоционального состояния студентов [2].

Основная цель данной научной работы — сравнить эффективность различных моделей машинного обуче-

ния для анализа тональности в контексте электронного обучения. Путем оценки и сравнения разных моделей, мы стремимся определить наиболее эффективный подход для захвата эмоций студентов в онлайн-среде обучения. Эти знания будут ценными для разработчиков платформ электронного обучения, преподавателей и исследователей при создании более эмоционально осведомленных систем, которые удовлетворяют потребностям студентов и способствуют более активному и эффективному обучению.

Обзор литературы

В различных исследованиях было изучено применение анализа тональности в электронном обучении для понимания эмоций, мнений и отношения студентов. Методы анализа тональности в электронном обучении в основном фокусировались на анализе текстовых данных из дискуссионных форумов, оценок курсов, социальных медиа и обратной связи от студентов [6]. В предыдущих исследованиях были использованы разные техники анализа тональности в электронном обучении, такие как подходы на основе лексикона, контролируемое машинное обучение и глубокое обучение. Эти исследования продемонстрировали потенциал анализа тональности в улучшении учебного опыта студентов и информировании образовательных стейкхолдеров о областях, требующих улучшения.

Обзор моделей машинного обучения для анализа тональности

1. Контролируемое обучение

Контролируемое обучение включает обучение модели с помощью размеченных данных, где каждый входной пример сопоставлен с соответствующей меткой выходных данных. Популярные алгоритмы контролируемого обучения для анализа тональности включают наивный Байесовский классификатор, машины опорных векторов (SVM) и деревья решений [11]. Эти модели широко используются для классификации текста и задач анализа тональности, предлагая конкурентоспособную производительность в различных областях.

2. Неконтролируемое обучение

Методы неконтролируемого обучения не зависят от размеченных данных и в основном используются для кластеризации, уменьшения размерности и моделирования тем. В контексте анализа тональности, техники неконтролируемого обучения включают подходы на основе лексикона, такие как SentiWordNet [8] и VADER [9], которые используют predetermined лексиконы тональности для оценки полярности текста. Методы неконтролируемого обучения могут быть преимуществен-

ными в случаях, когда размеченные данные редки или недоступны.

3. Глубокое обучение

Модели глубокого обучения, в частности нейронные сети, стали популярными в последние годы благодаря их способности учиться сложным представлениям из данных большого масштаба. Рекуррентные нейронные сети (RNN) и сети долгой краткосрочной памяти (LSTM) часто используются для задач анализа тональности, поскольку они могут улавливать долгосрочные зависимости и последовательные шаблоны в текстовых данных [12]. Сверточные нейронные сети (CNN) и трансформеры, такие как BERT [7], также показали обнадеживающие результаты в анализе тональности и других задачах обработки естественного языка.

Метрики оценки для моделей анализа тональности

Метрики оценки необходимы для количественной оценки производительности моделей анализа тональности. Общепринятые метрики оценки для анализа тональности включают точность, точность (precision), полноту (recall) и F1-меру. Точность измеряет долю правильно классифицированных экземпляров, в то время как точность, полнота и F1-мера полезны для оценки производительности на несбалансированных наборах данных. Матрицы ошибок также могут обеспечить визуальное представление производительности модели, иллюстрируя показатели истинно положительных, истинно отрицательных, ложно положительных и ложно отрицательных результатов.

Методология исследования

В этой научной работе мы используем набор данных, содержащий 3000 твитов, собранных с Twitter. Набор данных включает твиты, содержащие одно или несколько следующих ключевых слов, связанных с электронным обучением:

- Моос
- онлайн-курс
- цифровое обучение
- электронное обучение
- обучение онлайн
- онлайн обучение

Набор данных предоставляет разнообразный набор мнений и эмоций, выраженных пользователями, обсуждающими различные аспекты электронного обучения, такие как качество курсов, платформ и личный опыт.

1	Content	Date	Language	Location	Number of	Number of	In Reply To	Author Na	Author De	Author Sta	Author Fav	Author Fri	Author Fol	Author List	Author Ver	Author	
2	Our rates €	2021-04-19 19:00	en		0	0		Suregrade	Your succe	1723	0	170	62	1	False	@Timelywriters01	
3	Our rates €	2021-04-19 19:00	en		0	0		Excel Onlin	Hire a tear	5427	834	604	504	0	False	@online_excel	
4	@Reallifec	2021-04-19 19:00	en		0	0	@Reallifec	Coach Car	Father to t	1918	3425	350	236	4	False	@kcizz1e	
5	Our rates €	2021-04-19 19:00	en		0	0		Superior W	We offer r	3923	406	131	68	0	False	@SuperiorWrite13	
6	ATTENTIO	2021-04-19 19:00	en		3	1		zoe ♥ (dr	☑ good c	47751	192804	5964	7133	100	False	@POTTEROMENS	
7	We help er	2021-04-19 19:00	en		0	0		Superior W	We offer r	3923	406	131	68	0	False	@SuperiorWrite13	
8	We help er	2021-04-19 19:00	en		0	0		Perfected	We offer A	5458	14743	313	698	0	False	@perfectedwrite4	
9	Online Lea	2021-04-19 19:00	en		0	0		Regina Nic	Empoweri	2691	5599	474	74	0	False	@ImReginaNicole	
10	We are avi	2021-04-19 19:00	en		0	0		Superior W	We offer r	3923	406	131	68	0	False	@SuperiorWrite13	
11	@Thee_m	2021-04-19 19:00	en	KE	0	0	@Thee_m	The Overtl	MANCH	255042	104	444	1760	37	False	@Carytosh	
12	Our rates €	2021-04-19 19:00	en		0	0		W R I T E Y	PROFESSIC	9164	222	128	3965	2	False	@writegram	
13	Our rates €	2021-04-19 19:00	en		0	0		W R I T E Y	we write;C	20064	1945	398	4927	3	False	@write_wave	
14	Our rates €	2021-04-19 19:00	en		0	0		Superior W	We offer r	3923	406	131	68	0	False	@SuperiorWrite13	
15	@pr_marg	2021-04-19 19:00	en		0	0	@pr_marg	Donna Russell		23	73	22	2	0	False	@DonnaRu87737275	
16	My Trade	2021-04-19 19:00	en		0	0		DenDon60	Son, Broth		3	2	10	1	0	False	@DDon604
17	never thou	2021-04-19 19:00	en		0	0		loz		9622	14032	619	402	0	False	@lozaxk	
18	We are avi	2021-04-19 19:00	en		0	0		Superior W	We offer r	3923	406	131	68	0	False	@SuperiorWrite13	
19	@edsbs @	2021-04-19 19:00	en		0	0	@edsbs	Dee Seiffe	Retired frc	31999	63216	1414	307	0	False	@deeseiffer	
20	We are avi	2021-04-19 19:00	en		0	0		Purity Writ	The profici	39	14	4	2	0	False	@PurityWriter	
21	Our rates €	2021-04-19 19:00	en		0	0		KAIZEN WI	WE @kaiz	9842	3531	5000	645	1	False	@KaizenEssays	
22	If you wan	2021-04-19 19:00	en		0	0		TwentyOn	We believ	536	11	84	46	1	False	@TwentyOneLead	
23	Learn how	2021-04-19 19:00	en		0	0		MediaWis	We're a nc	3280	1231	392	15657	252	True	@mediawise	
24	@naomirv	2021-04-19 19:00	en		1	0	@naomirv	Steven Wil	If you're g	11739	6619	347	239	0	False	@StevenWilson777	
25	We are avi	2021-04-19 19:00	en		0	0		EssayWrit	We are ha	473	3970	5001	1045	0	False	@Best_Writers67	
26	@RogersH	2021-04-19 19:00	en		0	0	@RogersH	TKerr		1	0	4	0	0	False	@yaadytrk	
27	@Ofstedni	2021-04-19 19:00	en		0	0	@Ofstedni	Amy Joyn	Mum of 2	50	127	65	27	0	False	@ajoynes75	
28	more in th	2021-04-19 19:00	en		0	0	@ChildMe	Child Ment	We conn	76	79	24	16	0	False	@ChildMentorship	
29	We ensure	2021-04-19 19:00	en		0	0		PAPERS W	Competiti	5921	2245	1387	478	2	False	@paperwritingpr	

Рис. 1. Список данных

Предварительная обработка и очистка данных

Перед анализом набора данных нам нужно предварительно обработать и очистить текстовые данные для повышения эффективности и производительности моделей машинного обучения. Этапы предварительной обработки включают:

- Удаление URL-ов, упоминаний и хештегов
- Приведение всего текста к нижнему регистру
- Удаление знаков пунктуации и специальных символов
- Токенизация текста на отдельные слова
- Удаление стоп-слов (общих слов типа 'the', 'and', 'is' и т.д.)
- Стемминг или лемматизация слов для приведения их к базовым формам

Эти шаги предварительной обработки гарантируют, что набор данных готов к последующему анализу и обучению модели.

Выбор модели машинного обучения

1. Критерии выбора модели

При выборе моделей машинного обучения для анализа тональности в электронном обучении мы учитываем следующие критерии:

- Производительность модели: способность модели точно классифицировать эмоции в данном наборе данных.
- Сложность модели: вычислительные ресурсы, необходимые для обучения и вывода.

- Интерпретируемость: насколько легко понять процесс принятия решений модели.
- Адаптивность: потенциал модели быть настроенной или адаптированной для других задач анализа эмоций в электронном обучении.

2. Выбранные модели для сравнения

Исходя из вышеупомянутых критериев, мы выбрали следующие модели машинного обучения для сравнения:

- Наивный Байес — это вероятностный классификатор, основанный на теореме Байеса, который предполагает независимость между признаками. Это простая и эффективная модель, которую часто используют в качестве базовой для задач классификации текста.
- Метод опорных векторов (SVM) — это популярная модель для задач бинарной классификации. Он стремится найти лучшую гиперплоскость, которая разделяет классы с максимальным зазором. Модель может быть расширена до многоклассовой классификации с использованием подхода один-против-всех или один-против-одного.
- Деревья решений — это интерпретируемые модели, которые рекурсивно разделяют данные на основе важности признаков, создавая структуру в виде дерева. Для анализа эмоций деревья решений могут помочь понять важность конкретных слов при определении полярности эмоций.
- Случайный лес — это метод обучения композиции, который объединяет несколько деревьев решений для повышения общей производительности и уменьшения переобучения. Эта модель

обеспечивает более надежную и точную классификацию по сравнению с отдельными деревьями решений.

Процедуры обучения и тестирования моделей

1. Разделение набора данных

Начальный этап процедуры обучения и тестирования моделей включает разделение набора данных на подмножество для обучения и подмножество для тестирования. Приблизительно 80% всего набора данных назначается для обучения моделей, а оставшиеся 20% — для тестирования. Этот подход позволяет обучать модели на одном наборе данных и тестировать на другом, что помогает оценить их способность обрабатывать незнакомые данные и дает реалистичную оценку их производительности.

2. Обучение моделей

Следующий этап включает обучение выбранных моделей машинного обучения, а именно, Наивного Байеса, метода опорных векторов (SVM), деревьев решений, случайного леса. Каждой модели предоставляются предварительно обработанные обучающие данные, состоящие из твитов и соответствующих им меток настроения. Затем модели учатся на этих данных, модифицируя свои внутренние параметры для минимизации отклонения между своими прогнозами и фактическими метками. Например, Наивный Байес вычисляет вероятности на основе частоты слов в каждом классе настроения, SVM находит оптимальную гиперплоскость для разделения различных классов.

3. Валидация и оценка моделей

После этапа обучения модели проверяются и оцениваются с использованием тестового набора данных. Каждая модель генерирует прогнозы меток настроения для тестовых данных, которые сравниваются с фактическими метками для определения производительности каждой модели. Производительность моделей оценивается с помощью нескольких метрик, таких как точность, точность, полнота и F1-оценка. Точность предлагает меру общей точности прогнозов моделей. Точность и полнота дают более глубокое понимание производительности каждой модели по отдельным классам настроения, что особенно важно, если набор данных несбалансирован. F1-оценка гармонизирует точность и полноту, давая одну метрику, которая учитывает эти соображения.

Кроме того, используются матрицы ошибок для визуального представления производительности моделей. Эти матрицы определяют количество истинно положительных, истинно отрицательных, ложно положительных

и ложно отрицательных прогнозов, сделанных моделями, тем самым предоставляя общий обзор их производительности. Сравнивая результаты этих оценок, целью является определение модели машинного обучения, наиболее подходящей для анализа тональности в контексте электронного обучения.

В сущности, этот надежный процесс обучения и тестирования разработан для определения того, какая модель машинного обучения может наиболее точно определить тональность студентов относительно электронного обучения. Из этого исследования будут получены ценные сведения, которые помогут заинтересованным сторонам электронного обучения улучшить опыт онлайн-обучения.

Результаты

В этом исследовании мы использовали программное обеспечение Orange Data Mining для обучения и оценки нескольких машинных моделей обучения с целью сравнения их производительности на основе различных оценочных метрик. Рассматриваемые модели были: Наивный Байес, Решающие деревья, Машина опорных векторов (SVM) и Случайный лес.

Производительность каждой модели была количественно оценена с использованием метрик, таких как Площадь под кривой (AUC), Точность классификации (CA), F1-мера, Точность (Precision) и Полнота.

Ниже представлены показатели производительности каждой модели:

Таблица 1.

Производительность моделей

Model	AUC	CA	F1 Score	Precision	Recall
Naive Bayes	0.811	0.412	0.377	0.734	0.412
Decision Tree	0.714	0.659	0.661	0.664	0.659
SVM	0.714	0.617	0.593	0.597	0.617
Random Forest	0.83	0.736	0.709	0.766	0.736

Далее мы подробнее рассмотрим производительность каждой модели, изучив их матрицы ошибок. Матрица ошибок — это табличное представление фактических и предсказанных значений, которое позволяет более детально увидеть производительность модели по различным классам. В нашем случае классами являются Нейтральные, Отрицательные и Положительные.

Матрицы ошибок для соответствующих моделей выглядят следующим образом:

Наивный Байес:

Таблица 2.

Матрица ошибок: Наивный Байес

	Предсказанный: Нейтральный	Предсказанный: Отрицательный	Предсказанный: Положительный	Сумма
Фактический: Нейтральный	126	5	2	133
Фактический: Отрицательный	56	57	1	114
Фактический: Положительный	248	33	59	340
Сумма	430	95	62	587

Решающие деревья:

Таблица 3.

Матрица ошибок: Решающие деревья

	Предсказанный: Нейтральный	Предсказанный: Отрицательный	Предсказанный: Положительный	Сумма
Фактический: Нейтральный	76	24	33	133
Фактический: Отрицательный	20	54	40	114
Фактический: Положительный	50	33	257	340
Сумма	146	111	330	587

SVM:

Таблица 4.

Матрица ошибок: SVM

	Предсказанный: Нейтральный	Предсказанный: Отрицательный	Предсказанный: Положительный	Сумма
Фактический: Нейтральный	45	9	79	133
Фактический: Отрицательный	7	38	69	114
Фактический: Положительный	39	22	279	340
Сумма	91	69	427	587

Случайный лес:

Таблица 5.

Матрица ошибок: Случайный лес

	Предсказанный: Нейтральный	Предсказанный: Отрицательный	Предсказанный: Положительный	Сумма
Фактический: Нейтральный	53	2	78	133
Фактический: Отрицательный	5	51	58	114
Фактический: Положительный	9	3	328	340
Сумма	67	56	464	587

Эти матрицы ошибок дают полное представление о производительности каждой модели с точки зрения правильно и неправильно классифицированных экземпляров по различным классам. Глубокий анализ этих матриц может дать ценные сведения

Анализ результатов

Модель Случайного леса продемонстрировала наивысшую производительность по всем метрикам: AUC 0.830, CA 0.736, F1-оценкой 0.709, точностью 0.766 и полнотой 0.736. Это указывает на то, что модель Случайного леса обеспечивает оптимальный баланс точности и полноты, делая ее наиболее надежной моделью среди протестированных на этом конкретном наборе данных.

Модель Наивного Байеса, несмотря на высокий AUC 0.811 и точность 0.734, показала относительно низкую производительность по другим метрикам. Это может быть связано с внутренним предположением модели о независимости признаков, которое может не соблюдаться в данном наборе данных.

Обе модели, Решающие деревья и SVM, показали идентичные AUC 0.714. Однако модель Решающих деревьев немного превзошла SVM по остальным метрикам, указывая на то, что она может быть лучше в обработке сложных отношений в данных.

Осмотрев матрицы ошибок, можно увидеть, что модель Случайного леса значительно лучше справилась с правильной классификацией экземпляров по всем классам. Это особенно заметно в классе 'Положительные', где модель правильно предсказала 328 экземпляров из 340. Модель Наивного Байеса, с другой стороны, особенно трудно далась классификация 'Положительного' класса, она ошибочно классифицировала значительное количество экземпляров.

В заключение, исходя из данного набора данных и метрик производительности, модель Случайного леса, по-видимому, является наиболее подходящей моделью для предсказания. Однако всегда полезно экспериментировать с различными конфигурациями моделей, инженерией признаков, или даже попробовать другие модели для улучшения производительности. В дальнейшем можно также исследовать, почему определенные модели работали так, как они работали, и соответствует ли это теоретическим сильным и слабым сторонам каждой модели.

Обсуждение

В ходе исследования было обнаружено, что модель Случайного леса превосходит другие модели по всем метрикам, что делает ее наиболее надежной для классификации твитов в этом наборе данных. Однако следует учесть, что результаты могут отличаться в зависимости

от особенностей данных и выбранных параметров модели. Так, Наивный Байес показал низкую производительность, вероятно, из-за нарушения предположения о независимости признаков. Модели Решающих деревьев и SVM показали схожие результаты, но деревья превзошли SVM по некоторым метрикам.

Заключение

Исследование подтвердило возможность использования моделей машинного обучения для анализа твитов и определения общих тенденций тональностей относительно электронного обучения. Однако необходимо продолжать работу над улучшением производительности моделей, исследованием других моделей и применением различных методов предобработки данных. Это поможет создать более надежные и точные модели для анализа данных социальных сетей.

ЛИТЕРАТУРА

1. R.A. Calvo and S. D'Mello, «Affect Detection: An Interdisciplinary Review of Models, Methods, and Their Applications», in IEEE Transactions on Affective Computing, vol. 1, no. 1, pp. 18–37, Jan. 2010.
2. B. Kort, R. Reilly and R.W. Picard, «An affective model of interplay between emotions and learning: reengineering educational pedagogy-building a learning companion», Proceedings IEEE International Conference on Advanced Learning Technologies, Madison, WI, USA, 2001, pp. 43–46.
3. Liu, B. (2012). Sentiment analysis and opinion mining. Synthesis Lectures on Human Language Technologies, 5, 1–167.
4. Savel'yeva, T.M. Spector, D. Merrill, J. Elen, & M.J. Bishop (eds): Handbook of Research on Educational Communications and Technology. Tech Know Learn 20, 123–128 (2015).
5. Rashid, T., & Asghar, H.M. (2016). Technology use, self-directed learning, student engagement, and academic performance: Examining the interrelations. Computers in Human Behavior, 63, 604–612.
6. D'Mello, S., Graesser, A. (2012). Dynamics of affective states during complex learning. Learning and Instruction, 22(2), 145–157.
7. Devlin, J., Chang, M.W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. In Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (pp. 4171–4186).
8. Esuli, A., & Sebastiani, F. (2006). SentiWordNet: A publicly available lexical resource for opinion mining. In Proceedings of the 5th Conference on Language Resources and Evaluation (LREC'06) (pp. 417–422).
9. Hutto, C.J., & Gilbert, E. (2014). VADER: A parsimonious rule-based model for sentiment analysis of social media text. In Eighth International Conference on Weblogs and Social Media (ICWSM-14) (pp. 216–225).
10. Iosifidis, V., & Ntoutsi, E. (2017). Large Scale Sentiment Learning with Limited Labels. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '17). Association for Computing Machinery, New York, NY, USA, 1823–1832.
11. Pang, B., Lee, L., & Vaithyanathan, S. (2002). Thumbs up? Sentiment classification using machine learning techniques. In Proceedings of the 2002 conference on Empirical methods in natural language processing (pp. 79–86). Association for Computational Linguistics.
12. Tang, D., Qin, B., & Liu, T. (2015). Document modeling with gated recurrent neural network for sentiment classification. In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing (EMNLP) (pp. 1422–1432).

© Або-Рашед Кнаан (Kanan.rashed@gmail.com); Польщикова Константин Александрович (polshchikov@bsu.edu.ru);

Головко Ярослав Юрьевич (Golovko.laroslav@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»