

**Письменный отзыв официального рецензента на докторскую работу Якунина Кирилла Олеговича на тему
«Разработка моделей и методов сбора, анализа и классификации медиа-публикаций на базе методов обработки
естественных языков», представленную на соискание степени «доктор философии» (Ph.D) по специальности**

6D07400 – «Вычислительная техника и программное обеспечение»

№ п/п	Критерии	Соответствие критериям (необходимо отметить один из вариантов ответа)	Обоснование позиции официального рецензента
1.	Тема докторской работы соответствует направлениям развития науки и/или государственным программам	<p>1.1 Соответствие приоритетным направлениям развития науки или государственным программам:</p> <p>1) Докторская работа выполнена в рамках проекта или целевой программы, финансируемого (ой) из государственного бюджета (указать название и номер проекта или программы)</p> <p>2) Докторская работа выполнена в рамках другой государственной программы (указать название программы)</p> <p>3)Докторская работа соответствует приоритетному направлению развития науки, утвержденному Высшей комиссией при Правительстве Республики Казахстан (указать направление)</p>	<p>Докторская работа выполнялась в рамках проекта программно-целевого финансирования (ПЦФ) КН МОН РК BR05236839 «Разработка информационных технологий и систем для стимулирования устойчивого развития личности как одна из основ развития цифрового Казахстана» в 2018-2020 годы (Институт информационных и вычислительных технологий КН МОН РК).</p>
2.	Важность для науки	Работа вносит существенный вклад в науку, а ее важность хорошо раскрыта/не раскрыта	Вынесенные на защиту положения содержат явную научную новизну и были тщательно верифицированы в ходе экспериментов.
3.	Принцип самостоятельности	Уровень самостоятельности: 1) Высокий; 2) Средний; 3) Низкий; 4) Самостоятельности нет	Личный вклад соискателя докторской работы состоит в формулировке и постановке задач, проведении теоретических и экспериментальных исследований, разработке методов мультикритериальной оценки медиаисточников MMA на основе Байесовской модели агрегации гетерогенных данных, разработке информационной системы мониторинга медиапространства Казахстана на базе методов NLP с

		описанием программной архитектуры и основным функционалом, разработке выводов и рекомендаций, что позволяет оценить уровень самостоятельности в проведений исследований, как высокий.
4.	Принцип внутреннего единства	<p>4.1 Обоснование актуальности диссертации:</p> <p>1) <u>Обоснование;</u> 2) Частично обоснована; 3) Не обоснована.</p> <p>Задача эффективной векторизации текстовых данных с целью последующей мультикритериальной классификации – одна из важнейших задач в области обработки естественных языков. Современные подходы к векторизации текстов обладают рядом недостатков – они либо слишком тривиальны (<i>bag-of-words</i>) либо наоборот требуют сложнейших моделей глубокого обучения и, следовательно, являются слабо интерпретируемыми (BERT, GPT).</p> <p>Любой новый подход к решению данного комплекса задач вызывает интерес и определяет актуальность настоящего диссертационного исследования. В частности, предлагаемые автором модели и методы, реализованные в рамках распределенной информационной системы, позволяют решать задачу мультикритериального анализа информационных трендов в медиа-пространстве с небольшим объемом необходимой ручной разметки.</p>
4.2	Содержание диссертации отражает тему диссертации:	<p>1) <u>Отражает;</u> 2) Частично отражает; 3) Не отражает</p> <p>Содержание диссертации отражает тему диссертации.</p>
4.3	Цель и задачи соответствуют теме диссертации:	<p>Цели и задачи, поставленные в работе, соответствуют теме диссертации и конкретизируют направление исследований.</p> <p>1) <u>соответствуют;</u> 2) частично соответствуют; 3) не соответствуют</p>

<p>4.4 Все разделы и положения диссертации логически взаимосвязаны:</p> <ol style="list-style-type: none"> 1) <u>полностью взаимосвязаны</u>; 2) взаимосвязь частичная; 3) взаимосвязь отсутствует <p>4.5 Предложенные автором новые решения (принципы, методы) аргументированы и оценены по сравнению с известными решениями:</p> <ol style="list-style-type: none"> 1) <u>критический анализ есть</u>; 2) анализ частичный; 3) анализ представляет собой не собственные мнения, а цитаты других авторов 	<p>Полученные в диссертационном исследовании научные результаты обладают внутренним единством, так как все они являются следствием решения одной единой задачи. Оценка внутреннего единства основана на логической связи последовательности элементов разработанного метода, выраженной в составе исследований и изложенной в диссертационной работе. Степень этого единства очень высока, так как каждый полученный результат является следствием предыдущего результата.</p> <p>Диссертационная работа является целостным научным исследованием, содержащим системный анализ состояния вопросов в исследуемой области, проработку актуальных направлений и обоснование достигнутых научных результатов. Соискателем раскрыты актуальность, конкретизированы проблемы, связанные с исследуемой темой диссертации.</p> <p>Предложен метод оценки межкорпусного тематического лисбаланса для решения найденных в ходе литературного обзора ограничений, в особенности необходимости больших объемов ручной экспертной разметки и низкой интерпретируемости современных моделей.</p> <p>Разработан мультикритериальный метод оценки медиа-источников MMA. Метод основан на синтезе байесовской модели агрегации критериев, также описанной в данном разделе, на методе анализа иерархий (АИР), позволяющим проводить относительную оценку важности критериев на целевой показатель, а также на применение тех или иных тематических моделей для поиска информационных трендов в корпусе текстов.</p>
---	--

5. Принцип научной новизны	<p>5.1 Научные результаты и положения являются новыми?</p> <ol style="list-style-type: none"> 1) <u>полностью новые;</u> 2) частично новые (новыми являются 25-75%); 3) не новые (новыми являются менее 25%) <p>5.2 Выводы диссертации являются новыми?</p> <ol style="list-style-type: none"> 1) <u>полностью новые;</u> 2) частично новые (новыми являются 25-75%); 3) не новые (новыми являются менее 25%) <p>5.3 Технические, технологические, экономические или управленческие решения являются новыми и обоснованными:</p> <ol style="list-style-type: none"> 1) <u>полностью новые;</u> 2) частично новые (новыми являются 25-75%); 3) не новые (новыми являются менее 25%) 	<p>Основные научные результаты и положения включают следующие пункты:</p> <ol style="list-style-type: none"> 1. Исследован вопрос влияния открытых информационных источников на общество, выявлены основные направления влияния, сформирован перечень информативных признаков, на основе которых можно оценить это влияние. 2. Исследованы существующие подходы классификации документов и векторизации текстов, выявлены проблемы и слабые стороны текущих решений, сформированы рекомендации. 3. Разработан подход векторизации текстов на основе тематической модели. <p>4. Разработан метод оценки межкорпусного тематического дисбаланса, позволяющий автоматически или полуавтоматически получать веса топиков по отношению к заданному признаку.</p> <p>5. Разработан метод мультикритериальной оценки медиа-источников MMA на базе байесовской модели агрегации.</p> <p>6. Разработана распределенная информационная система на базе Open Source решений, позволяющая производить сбор (скрапинг), хранение, обработку текстовой информации, а также построение тематических моделей и классификаторов с возможностью визуализации полученных результатов.</p> <p>7. Собран корпус, состоящий из более чем 6 миллионов публикаций из казахстанских и российских источников, включая как тексты публикаций, так и мегаданные.</p>
6. Обоснованность основных выводов	Все основные выводы <u>основаны/не основаны</u> на весомых с научной точки зрения доказательствах либо достаточно хорошо обоснованы (для qualitative	Полученные и представленные в диссертационной работе научные результаты опираются на строгое математическое изложение

	7. Основные положения, выносимые на защиту	reseach и направлений подготовки по искусству и гуманитарным наукам)
		результаты и применяемых методов и основных положений и гуманитарным наукам)
		и подтверждаются результатами проведенного моделирования.
		Достоверность результатов обеспечивалась использованием современных средств и методик проведения исследований.
		Это дает основание считать полученные результаты достаточно обоснованными и достоверными.
		Необходимо ответить на следующие вопросы по каждому положению в отдельности:
		7.1 Доказано ли положение?
		1) доказано;
		2) скорее доказано;
		3) скорее не доказано;
		4) не доказано
		7.2 Является ли тривиальным?
		1) да;
		2) <u>нет</u>
		7.3 Является ли новым?
		1) да;
		2) нет
		7.4 Уровень для применения:
		1) узкий;
		2) средний;
		3) <u>широкий</u>
		7.5 Доказано ли в статье?
		1) да;
		2) нет
		Предложен метод векторизации текстовых документов с помощью тематической модели BigARTM; данный метод векторизации позволяет использовать данные, полученные из больших неразмеченных текстовых корпусов для получения эффективных векторных представлений, сопоставимых для ряда задач с векторизациями, полученным с помощью моделей глубокого обучения. Предложен метод оценки тематического межкорпусного дисбаланса для самообучения классификационной модели; данный метод

		<p>представляет собой новый подход в области semi-supervised learning, который был верифицирован при решении ряда задачи классификации текстов.</p> <p>Предложена методика многофакторной оценки социальной значимости публикации; данная методика предполагает способ для решения тяжело формализуемой задачи оценки социальной значимости с учётом различных факторов. Методика была апробирована на размеченном корпусе достаточного объёма.</p> <p>Предложена методика многокритериальной оценки масс-медиа MMA на базе байесовской системы агрегации, метода анализа иерархий (АНР) и тематического моделирования; данная методика является новым подходом к решению задачи оценки масс-медиа документов (публикаций) и источников.</p> <p>7.4 Положения выносимые на защиту имеют широкий уровень применения.</p> <p>7.5 Основные положения достигнутых результатов опубликованы в открытой печати, обсуждены в ряде международных и научно-практических конференций, а также опубликованы в рейтинговых журналах (Q1, Q2, Q3).</p>
8.	<p>Принцип достоверности</p> <p>Доверенность источников и предоставляемой информации</p>	<p>8.1 Выбор методологии – обоснован или методология достаточно подробно описана</p> <p>1) да; 2) нет</p> <p>8.2 Результаты диссертационной работы получены с использованием современных методов научных исследований и методик обработки и интерпретации данных с применением компьютерных технологий:</p> <p>1) да; 2) нет</p>

		<p>8.3 Теоретические выводы, модели, выявленные взаимосвязи и закономерности доказаны и подтверждены экспериментальным исследованием (для направлений подготовки по педагогическим наукам результаты доказаны на основе педагогического эксперимента):</p> <p>1) да;</p> <p>2) нет</p>	<p>8.3 Важные утверждения подтверждены/частично подтверждены/не подтверждены ссылками на актуальную и достоверную научную литературу</p> <p>8.5 Использованные источники литературы достаточно/не достаточно для литературного обзора</p>	<p>медиапространстве. Разработана распределённая интеллектуальная информационная системы Media Analytics, позволяющей проводить сбор, хранение и обработку текстовых данных.</p> <p>8.3 С поискателем в полной мере основаны теоретические выводы, методы, разработанные в ходе исследовательской работы.</p> <p>В рамках работы над диссертационным исследованием была разработана распределённая интеллектуальная информационная система Media Analytics, позволяющей проводить сбор, хранение и обработку текстовых данных. В частности, на базе этой системы реализован метод MMA (мультикритеральный метод оценки медиаисточников), а также проведены вычислительные эксперименты для валидации предложенных моделей и методов. На базе этой системы были проведены вычислительные эксперименты для валидации разработанных моделей и методов. Автором проведена всесторонняя валидация разработанных моделей и методов, было проведено сравнение эффективности предложенных методов с современными моделями классификации.</p> <p>8.4 Важные утверждения, приводимые в диссертационной работе, подтверждаются ссылками на актуальную и достоверную научную литературу.</p> <p>8.5 Список источников, использованных в диссертационной работе, состоит из 92 наименований, которых достаточно для литературного обзора по данной теме.</p>
9.	Принцип практической ценности	<p>9.1 Диссертация имеет теоретическое значение:</p> <p>1) да;</p> <p>2) нет</p>	<p>9.1 В научно-исследовательской работе внимание уделено исследованию, которое является актуальным</p>	

		и имеет теоретическую и прикладную значимость. Научные результаты применимы для многокритериальной оценки медиапространства и автоматического поиска информационных трендов.	
9.2	Диссертация имеет практическое значение и существует высокая вероятность применения полученных результатов на практике:	9.2 Диссертация имеет практическое значение и существует высокая вероятность реального использования распределённой интеллектуальной информационной системы Media Analytics, позволяющей проводить сбор, хранение и обработку текстовых данных.	
9.3	Предложения для практики являются новыми?	9.3 Разработанная система решает стандартные для систем медиа-мониторинга задачи, включая сбор текстовых данных, а также поиск, фильтрацию, визуализацию данных. Соискатель предлагает в работе другие варианты практического применения: применение автоматического тематического моделирования, оценку межкорпусного дисбаланса, а также применение предложенных в работе моделей классификации (включая метод ММА). Таким образом, предложения для практики являются в основном новыми.	
10.	Качество написания и оформления	Качество академического письма: 1) <u>высокое;</u> 2) среднее; 3) ниже среднего; 4) низкое.	Диссертация написана грамотным научно-техническим, доступным для чтения, языком. В диссертационной работе имеются незначительные стилистические ошибки, не снижающие качества диссертационной работы.

Заключение. Проведена качественная научно-исследовательская работа, по результатам которой получены актуальные, новые результаты, имеющие теоретическую и прикладную значимость, разработана и предложена методика мультифакторной оценки социальной значимости на базе многокритериальной методики оценки масс-медиа MMA с использованием тематической векторизации текстовых документов. Разработана архитектура и программная реализация информационной системы для сбора, обработки и оценки масс-медиа текстов и социальных сетей Media Analytics,

включающей предложенную методику оценки, а также ее оценку и верификацию. На основании вышеизложенного рекомендую присудить Якунину Кириллу Олеговичу степень доктора философии (Ph.D) по специальности 6D070400 – «Вычислительная техника и программное обеспечение».

Официальный рецензент, к.т.н., асистент-профессор, декан факультета

Компьютерных технологий и кибербезопасности
АО «Международный Университет Информационных Технологий


Сейлова Н.А.



Подпись указанного лица **УДОСТОВЕРДИЛ**

Селюрова
Надежда

11.11.2012

