

## ГИБРИДНЫЙ МЕТОД АНАЛИЗА ОБРАТНОЙ СВЯЗИ И ОПТИМИЗАЦИИ ВЕСОВ КЛЮЧЕВЫХ ПАРАМЕТРОВ В СИСТЕМАХ ИИ

Ма Д.<sup>1</sup>, ✉ [dantingma65@gmail.com](mailto:dantingma65@gmail.com), [orcid.org/0009-0004-2021-5145](https://orcid.org/0009-0004-2021-5145)

Шичкина Ю. А.<sup>1</sup>, [strange.y@mail.ru](mailto:strange.y@mail.ru), [orcid.org/0000-0001-7140-1686](https://orcid.org/0000-0001-7140-1686)

<sup>1</sup>Санкт-Петербургский государственный электротехнический университет «ЛЭТИ»  
им. В. И. Ульянова (Ленина), ул. Профессора Попова, 5, корп. 3, 197022, Санкт-Петербург, Россия

### Аннотация

Понимание пользовательских предпочтений играет важную роль в персонализированных сервисах и интеллектуальных системах. Достигается это понимание путем организации обратной связи в разных формах, наиболее предпочтительной из которых является форма естественного языка. Но в этом случае необходимо точное определение ключевых признаков пользовательской обратной связи и динамическая оптимизация значимости (весов) этих признаков для повышения точности принятия решений системой. Сегодня существуют значительные ограничения у традиционных методов в области извлечения ключевых признаков обратной связи из текстов на естественном языке и адаптивности распределения весов. В данной работе рассматривается новый метод извлечения ключевых признаков пользовательской обратной связи и распределения их весов на основе предварительного многоитерационного взаимодействия пользователя и системы ИИ. Данный метод интегрирует четыре основных модуля: извлечения признаков на основе модели YAKE, персонализированного моделирования весов с помощью модели TF-IDF, семантического слияния векторных представлений с классификацией признаков и динамического распределения весов по ключевым признакам. Таким образом создается механизм прямого отображения пользовательской обратной связи на совокупность весов признаков, участвующих в построении модели для принятия решений в системах ИИ. Новизна метода заключается в разработке алгоритма извлечения ключевых слов YAKE с улучшенной семантической и признаковой плотностью; алгоритма расчета весов TF-IDF с интеграцией исторических пользовательских предпочтений и персонализацией весов; механизма классификации признаков на основе семантического сходства; оптимизации процессов извлечения признаков и распределения весов по признакам. Для тестирования метода использовалась система прогнозирования эмоционального состояния с непрерывным сбором данных от 16 пользователей в течение 30 дней. Результаты показали, что предложенный метод достигает точности прогнозирования эмоций 78,4 %, что на 23 % выше базовых методов. Отмечается значительное повышение удовлетворенности пользователей прогнозами системы и существенное сокращение времени достижения стабильного распределения весов признаков.

**Ключевые слова:** *пользовательская обратная связь; извлечение признаков; оптимизация весов; многоитерационное взаимодействие; персонализированная система; машинное обучение; искусственный интеллект.*

**Цитирование:** Ма Д., Шичкина Ю. А. Гибридный метод анализа обратной связи и оптимизации весов ключевых параметров в системах ИИ // Компьютерные инструменты в образовании. 2026. № 1. С. 57–73. doi:10.32603/2071-2340-2026-1-57-73

## 1. ВВЕДЕНИЕ

С быстрым развитием технологий искусственного интеллекта понимание пользовательских предпочтений стало ключевой технологией для реализации персонализированных сервисов и адаптивной оптимизации интеллектуальных систем [1]. В данной работе под признаком понимается характеристика, извлекаемая из текстовой обратной связи пользователя, которая может влиять на решение системы. Вес признака — это числовой параметр, определяющий степень влияния соответствующего признака на итоговое решение модели. Точный анализ истинных потребностей и предпочтений, содержащихся в пользовательской обратной связи, имеет критическое значение для различных систем: рекомендательных, интеллектуального обслуживания клиентов, поисковых и др. [2]. Пользовательская обратная связь представляет важный источник данных для оптимизации весов признаков, используемых в модели принятия решений. Механизм обработки обратной связи позволяет выделять ключевые признаки из текстовых сообщений пользователей и напрямую оптимизировать соответствующие веса этих признаков в модели. Существующие исследования показывают, что традиционные механизмы фиксированного распределения весов признаков сложно адаптируются под разнообразие и сложность форм, а также манеры предоставления пользовательской обратной связи [3]. Пользовательская обратная связь содержит богатую информацию о ключевых признаках, отражающих индивидуальные предпочтения пользователя. Эффективное извлечение информации о таких признаках и оптимизациях весов на основе анализа обратной связи становится ключевой задачей для повышения точности и адаптивности интеллектуальных систем.

Развитие технологий обработки пользовательской обратной связи прошло эволюционный путь от простой статистики к глубокому обучению. Ранние исследования сосредоточивались преимущественно на методах, основанных на статистических признаках. Метод TF-IDF, предложенный Salton и соавторами [4], заложил основу извлечения признаков из текстов на естественном языке. Однако данный метод учитывает только статистику частоты слов, игнорируя семантическую информацию. Впоследствии Rocchio [5] в исследовании релевантной обратной связи предложил механизм оптимизации весов признаков, однако его статический способ распределения весов признаков ограничивает возможности адаптации модели к индивидуальным особенностям пользователя.

В последние годы методы глубокого обучения получили широкое применение в обработке пользовательской обратной связи [6]. Модель BERT, предложенная Devlin и соавторами [7], добилась значительных прорывов в семантическом понимании, однако её высокая вычислительная сложность делает её трудно применимой в условиях реального времени. Алгоритм YAKE, разработанный Campos и соавторами [8], демонстрирует превосходную производительность в извлечении ключевых слов, но в нём отсутствует рассмотрение семантической плотности. В области оптимизации весов традиционные методы преимущественно используют градиентный спуск [9] или генетические алгоритмы [10] и другие стратегии глобальной оптимизации. Эти методы плохо подходят для обработки ключевых признаков в пользовательской обратной связи на естественном языке в условиях динамического изменения самой обратной связи. Метод оптимизации весов реле-

вантности, предложенный Robertson и соавторами [11], учитывает пользовательскую обратную связь для уточнения значимости признаков. Такой подход необходим для повышения точности модели за счет учета индивидуальных реакций пользователя. Однако данный метод не позволяет устанавливать прямое отображение извлеченных признаков на распределение весов признаков в модели.

Анализ существующих исследований показывает, что современные методы при обработке пользовательской обратной связи сталкиваются с тремя основными проблемами. Во-первых, проблема полноты извлечения признаков. Каждый алгоритм может эффективно извлекать лишь ограниченную совокупность признаков определенного типа. Во-вторых, проблема адаптивности распределения весов, то есть отсутствие у существующих методов возможности динамически изменять веса признаков в зависимости от особенностей поступающей обратной связи. Существующие стратегии преимущественно используют механизмы статического распределения весов. В них отсутствует способность динамической корректировки в соответствии с характеристиками пользовательской обратной связи. Эта статичность ограничивает способность системы адаптироваться к персонализированным потребностям пользователей. В-третьих, проблема отображения признак-вес. В традиционных методах отсутствует механизм перехода от текста пользовательской обратной связи к весам признаков в модели. Это приводит к тому, что процессы извлечения признаков и оптимизации весов независимы друг от друга, что затрудняет многопараметрическую оптимизацию по признакам и их весам.

На основе проведенного анализа в настоящей работе приводится решение проблемы, которую формально можно определить следующим образом: дано множество текстов пользовательской обратной связи  $U = u_1, u_2, \dots, u_m$  и соответствующие пользовательские аннотации  $Y = y_1, y_2, \dots, y_m$  (целевые значения или метки, предоставляемые пользователем). Необходимо разработать механизм итерационного взаимодействия между алгоритмами извлечения признаков и оптимизации весов, который посредством функции извлечения признаков  $\varphi(u_i)$  и функции отображения весов  $\psi(u_i, y_i)$  реализует динамическую оптимизацию весов каждого влияющего признака системы, минимизируя ошибку прогнозирования  $L(f(W), Y)$ , где  $W$  — вектор весов признаков,  $f(W)$  — функция прогноза системы на основе взвешенных признаков,  $L$  — функция потерь между системным прогнозом и пользовательскими аннотациями.

В качестве решения указанной проблемы в настоящей работе предлагается метод извлечения признаков пользовательской обратной связи и оптимизации весов признаков, основанный на многоитерационном взаимодействии между алгоритмами. Новизна данного метода заключается в следующем:

- 1) построен механизм взаимодействия между алгоритмами YAKE, TF-IDF и семантического анализа путём интеграции усовершенствованного алгоритма извлечения ключевых слов YAKE, персонализированного расчета весов на основе TF-IDF и семантического слияния векторных представлений GloVe и FastText. Реализуется объединение статистических, семантических и морфологических характеристик текста;
- 2) модифицирован алгоритм YAKE путем добавления интеграции семантической плотности и плотности признаков, разработан метод расчета весов TF-IDF с учетом истории пользовательских предпочтений;
- 3) построен механизм прямого отображения текста пользовательской обратной связи на веса признаков, влияющих на качество работы системы. Это позволяет реализовать многопараметрическую оптимизацию по признакам и их весам.

В данной статье также представлено экспериментальное подтверждение эффективности метода с использованием системы прогнозирования эмоционального состояния человека. Тестирование было проведено на основе данных о психофизиологическом состоянии 16 добровольцев, собранных в течение 30 дней. Результаты показывают значительные улучшения как в точности прогнозирования, так и в удовлетворенности пользователей.

Статья построена следующим образом. Во втором разделе приводится описание предлагаемого метода извлечения признаков и оптимизации весов, включая формализацию задачи и ключевые модули. В третьем разделе описывается дизайн и реализация эксперимента по верификации метода. В четвертом разделе представлены результаты эксперимента и их анализ. В пятом разделе подводятся итоги работы и обсуждаются перспективы дальнейших исследований.

## 2. МЕТОД ИЗВЛЕЧЕНИЯ ПРИЗНАКОВ ПОЛЬЗОВАТЕЛЬСКОЙ ОБРАТНОЙ СВЯЗИ И ОПТИМИЗАЦИИ ИХ ВЕСОВ

В данном разделе приводится описание общей архитектуры предлагаемого метода извлечения признаков пользовательской обратной связи и оптимизации весов на основе интеграции алгоритмов, а также ключевых модулей системы.

### 2.1. Формализация задачи оптимизации весов

Пусть интеллектуальная система основана на векторе признаков  $F = [f_1, f_2, \dots, f_n]^T$  и векторе весов  $[w_1, w_2, \dots, w_n]^T$  для прогнозирования состояния:

$$Y_{system} = g(W^T F) = g\left(\sum_{i=1}^n w_i f_i\right),$$

где  $g$  — функция активации,  $Y_{system}$  — выходные данные интеллектуальной системы, например прогноз состояния пользователя.

Набор данных пользовательской обратной связи это множество  $U = \{(u_1, y_1), (u_2, y_2), \dots, (u_m, y_m)\}$ , где  $u_j$  представляет собой текстовую обратную связь пользователя на прогноз системы  $Y_{system}$ ,  $y_j$  — истинное значение (правильный ответ), предоставленное пользователем в качестве целевой метки.

Задача заключается в оптимизации вектора весов  $W$  путём анализа текстовой пользовательской обратной связи  $u_j$ , таким образом, чтобы сделать прогноз системы  $Y_{system}(W)$  ближе к пользовательским аннотациям  $y_j$ :

$$W^* = \arg \min_W \sum_{j=1}^n L(Y_{system}(W), y_j) + \lambda \Omega(W),$$

где  $L$  — функция потерь,  $y_j$  — целевая метка, предоставленная пользователем.

Архитектура предложенного в данной работе метода основана на принципе многоуровневого взаимодействия четырех модулей. Посредством сочетания этих модулей реализуется комплексное извлечение признаков и обеспечивается оптимизация весов. Основой архитектуры является блок, сочетающий процессы полного извлечения признаков, классификации признаков на основе семантической близости и механизма двунаправленной верификационной обратной связи, как показано на рисунке 1.

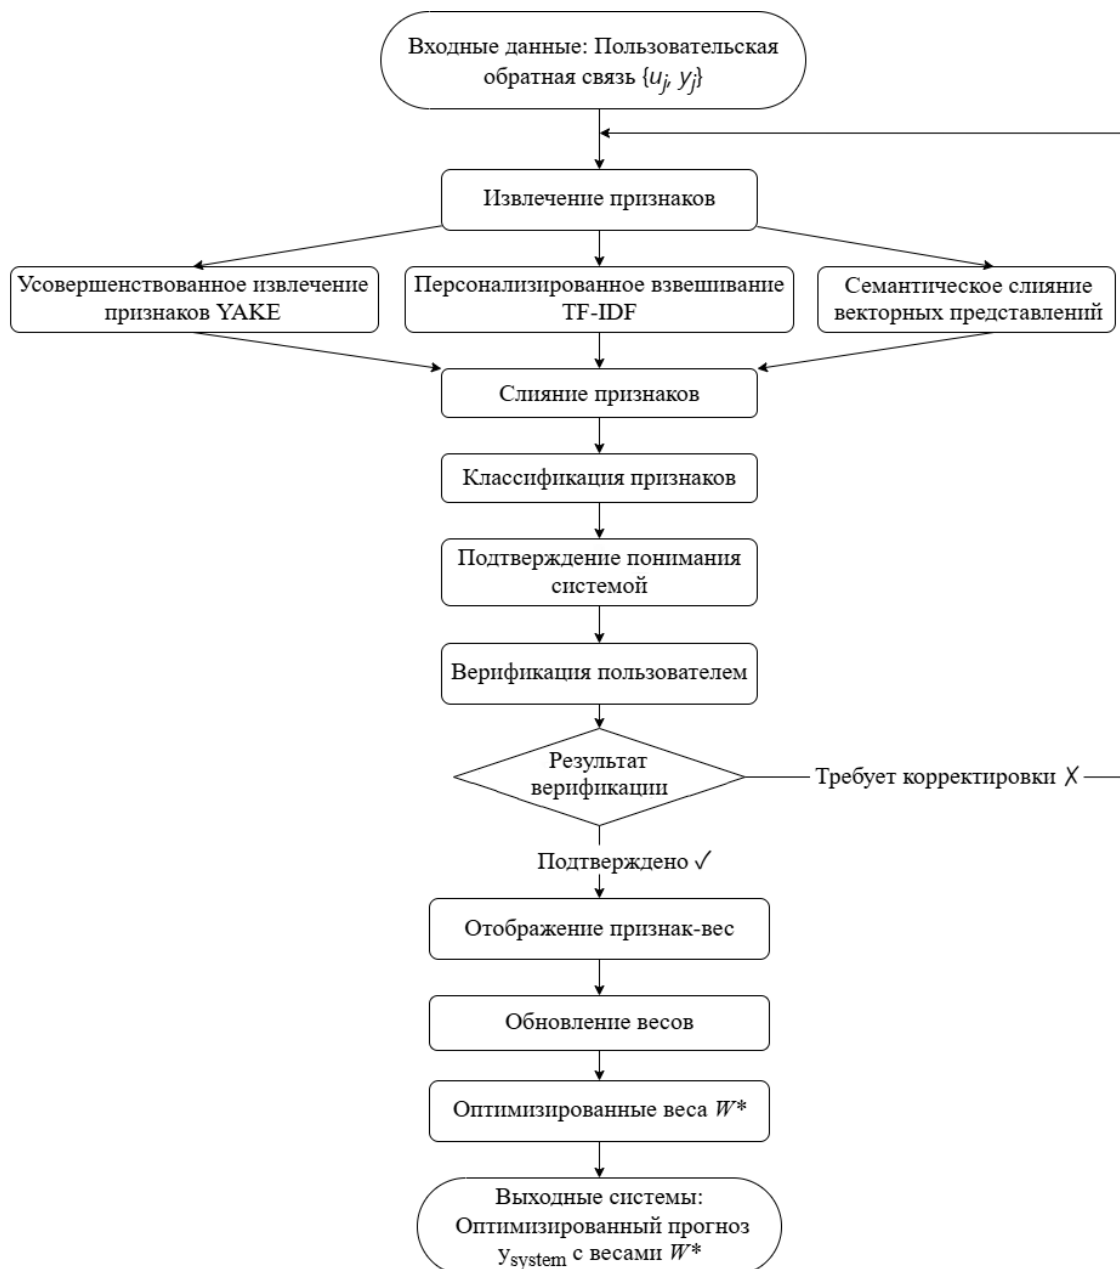


Рис. 1. Схема процесса обработки пользовательской обратной связи с взаимодействием

Далее будут подробно рассмотрены функциональные особенности каждого из указанных модулей.

## 2.2. Модуль усовершенствованного процесса извлечения признаков на основе алгоритма YAKE

Модуль усовершенствованного процесса извлечения признаков на основе алгоритма YAKE отвечает за поиск ключевой информации в тексте пользовательской обратной связи. Традиционный алгоритм YAKE выявляет ключевые слова путём рассмотрения много-

мерных лексических признаков. В нем используется следующая формула расчета оценки:

$$Score_{YAKE}(w) = \frac{T_w \times P_w}{(P_L + P_R) \times S_w},$$

где  $T_w$  представляет частотную статистику лексемы  $w$ ,  $P_w$  представляет позиционный вес лексемы  $w$ ,  $P_L$  и  $P_R$  соответственно представляют веса левого и правого контекстов,  $S_w$  представляет грамматические признаки лексемы  $w$ . Однако традиционный алгоритм YAKE при обработке текста пользовательской обратной связи часто игнорирует семантическую значимость и категории признаков лексем. Эти признаки имеют важное значение для понимания областей интереса пользователей. Поэтому в настоящей работе был разработан усовершенствованный алгоритм YAKE путем его дополнения двумя измерениями: семантической плотностью и плотностью признаков:

$$Score_{Enhanced}(w) = Score_{YAKE}(w) \times (1 + \alpha \cdot SD(w) + \beta \cdot FD(w)),$$

где семантическая плотность  $SD(w)$  рассчитывается с использованием заранее обученного семантического словаря:

$$SD(w) = \sum_{s \in S_w} \frac{|semantic(s)|}{\sqrt{|S_w|}}$$

где  $S_w$  — множество предложений, содержащих лексему  $w$ .

Плотность признаков  $FD(w)$  рассчитывается на основе словаря доменных признаков:

$$FD(w) = \log \left( 1 + \frac{freq_{domain}(w)}{freq_{general}(w)} \right),$$

где  $\alpha$  и  $\beta$  — регуляровочные параметры, определяемые с помощью кросс-валидации.

### 2.3. Модуль моделирования персонализированных весов TF-IDF

Модуль моделирования персонализированных весов TF-IDF реализует расчет весов признаков путём учёта закономерностей предыдущего поведения конкретного пользователя. Статический способ распределения весов традиционного метода TF-IDF [4] не отражает персонализированные особенности выражения обратной связи различными пользователями. Персонализированный метод TF-IDF, предложенный в данной работе, заключается в следующем:

$$TF-IDF^*(w, d, D, u) = TF(w, d) \times IDF(w, D) \times PW(w, u),$$

где вес  $PW(w, u)$  динамически оптимизирует лексический вес на основе предпочтений из предыдущей обратной связи пользователя:

$$PW(w, u) = \frac{1}{|H_u|} \sum_{h \in H_u} Relevance(w, h) \times Decay(t_h),$$

где  $H_u$  представляет множество исторических эмоциональных реакций пользователя  $u$ ,  $Relevance(w, h)$  представляет собой релевантность лексемы  $w$  и исторических реакций  $h$ ,  $Decay(t_h)$  представляет коэффициент временного затухания.

## 2.4. Модуль семантического слияния векторных представлений и классификации признаков

Модуль семантического слияния векторных представлений представляет собой механизм слияния двух взаимодополняющих векторных моделей слов GloVe и FastText. Он основан на объединении преимуществ характеристик различных моделей. Модель GloVe основана на глобальной статистической информации совместного появления лексем и превосходно работает в задачах поиска семантических связей между лексемами. Она особенно подходит для семантического представления обычных эмоциональных лексических единиц [14]. Модель FastText путём анализа информации подслов может эффективно обрабатывать морфологические признаки лексем. Она имеет значительные преимущества перед традиционными моделями (такими как Word2Vec) в векторном представлении профессиональной терминологии и низкочастотных лексем [15].

Для использования преимуществ этих двух моделей в настоящей работе предлагается стратегия адаптивного взвешенного слияния для построения улучшенного семантического вектора:

$$v_{semantic}(w) = \gamma(w) \cdot v_{GloVe}(w) + (1 - \gamma(w)) \cdot v_{FastText}(w),$$

где  $\gamma(w)$  — адаптивный вес слияния, связанный с лексемой:

$$\gamma(w) = \sigma(\alpha_{freq} \cdot \log(freq(w)) + \alpha_{len} \cdot len(w) + \alpha_{pos} \cdot pos(w)),$$

где  $\sigma$  — функция sigmoid,  $freq(w)$  — частота слов,  $len(w)$  — длина слов,  $pos(w)$  — признаки частей речи,  $\alpha_{freq}, \alpha_{len}, \alpha_{pos}$  — обучаемые параметры.

Слитый семантический вектор объединяет глобальные статистические признаки и локальные морфологические признаки, повышая точность и стабильность семантического представления лексем. На основе улучшенного семантического вектора семантическое сходство между лексическими единицами рассчитывается как:

$$Sim_{semantic}(w_1, w_2) = \frac{v_{semantic}(w_1) \cdot v_{semantic}(w_2)}{|v_{semantic}(w_1)| \times |v_{semantic}(w_2)|}.$$

Модуль классификации признаков отвечает за интеллектуальную классификацию текста пользовательской обратной связи по предварительно определенным типам признаков. Это обеспечивает точное определение типа признаков для последующей оптимизации весов. Данный модуль непосредственно использует результаты семантического слияния векторных представлений. Путём расчета семантического сходства реализуется классификация признаков без дополнительных расходов на обучение классификатора. Типы признаков могут гибко определяться в соответствии с конкретными сценариями применения.

Процесс классификации основан на расчете сходства между семантическим слитым вектором текста пользовательской обратной связи и семантическими центрами предварительно определенных признаков. Сначала система строит семантический центральный вектор для каждого типа признаков:

$$C_{feature_i} = \frac{1}{|S_i|} \sum_{w \in S_i} v_{semantic}(w),$$

где  $S_i$  — множество исходных лексических единиц признака  $i$ ,  $v_{semantic}(w)$  — семантический слитый вектор лексемы  $w$ . Затем рассчитывается сходство между общим семанти-

ческим представлением текста пользовательской обратной связи и центрами каждого признака:

$$P(feature_i|F_{text}) = \frac{\exp(sim(v_{text}, C_{feature}))}{\sum_{j=1}^N \exp(sim(v_{text}, C_{feature}))},$$

где  $v_{text}$  — семантический слитый вектор текста,  $N$  — общее количество типов признаков.

## 2.5. Модуль динамического распределения весов

Модуль динамического распределения весов является основным управляющим механизмом всей архитектуры. Он отвечает за реализацию комплексной оптимизации извлечения признаков и распределения весов на основе результатов классификации признаков, активных пользовательских аннотаций и объяснений причин пользовательских аннотаций в текстовой обратной связи. Механизм динамического распределения весов, разработанный в данной работе, устанавливает отображение извлеченных признаков на оптимизированные веса с помощью комплексного анализа текста пользовательской обратной связи, реализуя адаптивную системную оптимизацию.

**Механизм двунаправленной верификации обратной связи:** в системе заложен механизм двунаправленной верификации пользовательской обратной связи и подтверждения понимания системой полученного текста обратной связи. Этот механизм представляет собой процесс циклического интерактивного обучения. Пользователь сначала посредством предустановленных опций активно выбирает или исправляет системные выходные данные, затем предоставляет текстовую обратную связь для объяснения причин. Система на основе комплексного анализа извлекает ключевую информацию о признаках, затем генерирует сообщение с подтверждением понимания для пользовательской верификации:

$$Feedback_{dual} = \{Label_{user}, Text_{reason}\} \rightarrow Understanding_{system} \rightarrow Confirmation_{user},$$

где  $Label_{user}$  — ожидаемый выход, помеченный пользователем,  $Text_{reason}$  — текстовое объяснение пользователя к данной метке. Система на основе комплексного анализа извлекает ключевую информацию о признаках, затем генерирует  $Understanding_{system}$  для подтверждения пользователем своего понимания содержания обратной связи. Пользователь посредством  $Confirmation_{user}$  подтверждает или исправляет понимание системы, реализуя двунаправленное верификационное обучение.

**Извлечение признаков:** система реализует комплексное извлечение ключевых признаков из текстовой пользовательской обратной связи с помощью трех алгоритмов YAKE, TF-IDF и семантического анализа:

$$R_{final} = W_{YAKE} \times R_{YAKE} + W_{tfidf} \times R_{tfidf} + W_{semantic} \times R_{semantic},$$

где  $R_{YAKE}$ ,  $R_{tfidf}$ ,  $R_{semantic}$  соответственно представляют результаты извлечения признаков тремя алгоритмами,  $W_{YAKE}$ ,  $W_{tfidf}$ ,  $W_{semantic}$  — веса слияния, адаптивно скорректированные с помощью механизма градиентного спуска и нормализованные softmax, удовлетворяющие условиям:  $W_{YAKE} + W_{tfidf} + W_{semantic} = 1$ .

**Прямое отображение «признак-вес»:** на основе извлеченных ключевых признаков система устанавливает прямое отображение текста пользовательской обратной связи на веса признаков:

$$W_{new} = W_{old} + \Delta W(R_{final}, Label_{user}),$$

где  $\Delta W$  представляет вектор оптимизации весов на основе результатов извлечения признаков и пользовательских аннотаций:

$$\Delta w_i = \eta \cdot P(\text{feature}_i | F_{\text{text}}) \cdot \sum_{k \in \text{Keywords}} \text{Mapping}(k, f_i) \cdot \text{Intensity}(k) \cdot \text{Sign}(\text{Label}_{\text{user}}),$$

где  $P(\text{feature}_i | F_{\text{text}})$  — достоверность классификации признаков,  $\text{Mapping}(k, f_i)$  представляет отношения отображения ключевого слова  $k$  и признака  $f_i$ ,  $\text{Intensity}(k)$  — важность ключевого слова,  $\text{Sign}(\text{Label}_{\text{user}})$  — направление оптимизации на основе пользовательских аннотаций.

**Адаптивная оптимизация весов признаков:** система с помощью механизма градиентного спуска автоматически оптимизирует веса признаков после слияния результатов работы трех алгоритмов, реализуя оптимизацию весов по следующим формулам:

$$W_{YAKE}(t+1) = W_{YAKE}(t) + \eta \cdot \frac{\partial L}{\partial W_{YAKE}},$$

$$W_{TFIDF}(t+1) = W_{TFIDF}(t) + \eta \cdot \frac{\partial L}{\partial W_{TFIDF}},$$

$$W_{\text{semantic}}(t+1) = W_{\text{semantic}}(t) + \eta \cdot \frac{\partial L}{\partial W_{\text{semantic}}},$$

где  $L$  — функция потерь на основе активных пользовательских аннотаций:  $L = |Y_{\text{system}} - \text{Label}_{\text{user}}|^2$ . После обновления весов выполняется нормализация с помощью функции softmax для выполнения требований по ограничениям на веса признаков:

$$W_{\text{norm}}(\text{alg}) = \frac{\exp(W_{\text{alg}})}{\sum_j \exp(W_j)}$$

Благодаря интегрированной работе вышеуказанных модулей система реализует полный замкнутый цикл от пользовательской обратной связи к оптимизации весов. Она может непрерывно обучаться и улучшаться, адаптируясь к персонализированным потребностям пользователей.

### 3. ДИЗАЙН И РЕАЛИЗАЦИЯ ЭКСПЕРИМЕНТА

Для верификации эффективности представленного в данной статье метода извлечения признаков пользовательской обратной связи и оптимизации их весов была разработана система по верификации пользовательской обратной связи. В отличие от традиционных статических методов анализа текста, данный эксперимент был направлен на реализацию динамического взаимодействия между пользователем и системой по анализу текста обратной связи и оптимизации весов признаков.

Система, построенная в ходе эксперимента, включает три основных компонента:

1. **Модуль прогнозирования эмоций:** система проводит оценку эмоционального состояния человека на основе многомерных векторов признаков и векторов весов.
2. **Модуль обработки пользовательской обратной связи:** система извлекает ключевые признаки из текста пользовательской обратной связи с помощью интегрированного метода и проводит семантическую классификацию результатов извлечения в соответствии с группами признаков.

3. **Модуль оптимизации весов:** система динамически оптимизирует веса каждого ключевого признака системы на основе извлеченных признаков обратной связи.

Оценка эмоций определяется как:

$$Emotion_{score} = \sum_{i=1}^n w_i \times f_i,$$

где  $w_i$  — вес  $i$ -го влияющего признака,  $f_i$  — текущее значение состояния данного признака. Система была протестирована на 16 пользователях. Продолжительность эксперимента 30 дней.

#### Описание набора данных и экспериментальных настроек

В эксперименте проводились прогнозирование и анализ эмоционального состояния каждого пользователя. Пространство ключевых признаков включало пять основных типов, семантические центры каждого признака определялись посредством исходных лексических единиц (см. таблицу 1).

**Таблица 1.** Типы признаков и примеры исходных лексических единиц семантических центров

| Тип признака             | Примеры исходных лексических единиц семантических центров |
|--------------------------|---|
| Признак окружающей среды | погода, температура, окружающая среда, климат, сезон      |
| Временной признак        | время, утро, вечер, рабочий день, выходной                |
| Личный признак           | работа, учеба, давление, задачи, эффективность            |
| Физиологический признак  | сон, усталость, здоровье, тело, дух                       |
| Социальный признак       | друзья, семья, коллеги, отношения, общение                |

#### Дизайн эксперимента:

- 16 пользователей были случайным образом разделены на две группы: экспериментальную и контрольную.
- Для прогнозирования эмоционального состояния каждого пользователя в экспериментальной группе применялся предложенный метод.
- Для прогнозирования эмоционального состояния каждого пользователя в контрольной группе применялся традиционный метод фиксированных весов.
- Продолжительность: 30 дней, многократный сбор данных ежедневно.
- Критерии качества данных: пользовательская обратная связь должна содержать не менее 10 слов для обеспечения достаточной информативности текста.

#### Сбор данных для анализа пользовательской обратной связи

Система использует механизм двунаправленного верификационного взаимодействия (взаимного подтверждения между пользователем и системой) для анализа пользовательской обратной связи. Сначала система на основе предварительно обученной модели дает суждение об эмоциональном состоянии. Затем пользователь посредством предустановленных опций выбирает или исправляет результаты работы системы и дает обратную связь в форме текста на естественном языке, объясняя конкретные причины своего выбора. Далее система с помощью описанного в этой статье метода извлекает ключевые признаки из текста обратной связи и генерирует свое понимание обратной связи для верификации пользователем, формируя полный цикл двунаправленной верификации.

В ходе эксперимента были собраны три типа данных для анализа пользовательской обратной связи. Ниже приведены примеры двунаправленной верификации взаимодействия.

**Пример подтверждающей обратной связи:**

- Суждение от системы: «Ваше текущее эмоциональное состояние “спокойное”».
- Предлагаемая пользователем корректировка состояния: “подавленное”, с вводом пояснения «Сегодня дождь, который способствует тому, что я чувствую себя подавленно».
- Понимание системой обратной связи пользователя: «Я понимаю, что ваше текущее эмоциональное состояние “подавленное”. Это связано с признаком “Признак окружающей среды”».
- Подтверждение пользователя: «Да, понимание правильное».

**Пример корректирующей обратной связи:**

- Суждение от системы: «Ваше текущее эмоциональное состояние “подавленное”».
- Предлагаемая пользователем корректировка состояния: “усталость”, с вводом пояснения «Погода влияет не сильно, главным образом недостаток сна привел к усталости».
- Понимание системой обратной связи пользователя: «Я понимаю, что ваше текущее эмоциональное состояние “усталость”. Оно связано с признаком “Признак окружающей среды”».
- Исправление пользователя: «Неправильно, оно связано с физиологическими признаками, не с погодой».

**Пример дополняющей обратной связи:**

- Суждение от системы: «Ваше текущее эмоциональное состояние “тревожное”».
- Предлагаемая пользователем корректировка состояния: “тревожное”, с вводом пояснения «Наверное, из-за работы, хотя семейные отношения тоже сыграли роль».
- Понимание системой обратной связи пользователя: «Я понимаю, что ваше текущее эмоциональное состояние “тревожное”. Это может быть связано с признаком “Личный признак”».
- Подтверждение пользователя: «Да, но также необходимо учитывать важность социальных отношений».
- Понимание системой обратной связи пользователя: «Я понимаю, что ваше текущее эмоциональное состояние “тревожное”. Это может быть связано с признаками “Личный признак” и “Социальный признак”».

### 3.1. Реализация эксперимента и верификация

Программное обеспечение для проведения эксперимента разработано на основе Python 3.9. Основные используемые библиотеки: YAKE, Scikit-Learn, Gensim. Система работает на сервере с памятью 16GB и поддерживает обновление весов в реальном времени.

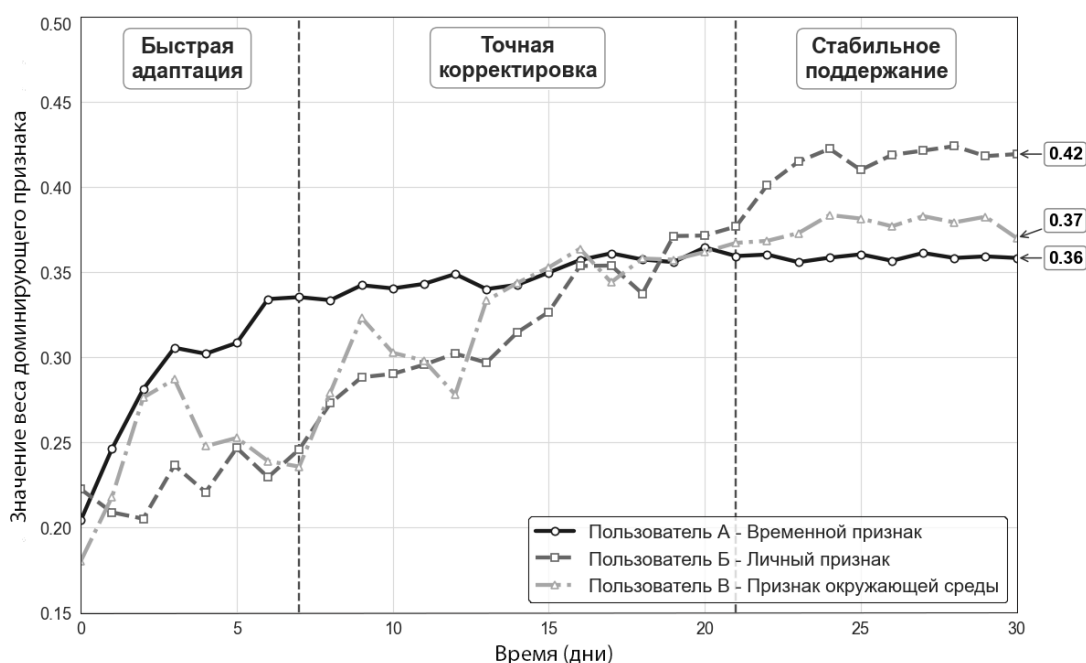
Настройки ключевых параметров в эксперименте:

- Скорость обучения  $\eta$ : 0,01.
- Начальные значения весов слияния алгоритмов: YAKE(0,2), TF-IDF(0,3), семантический анализ(0,5).
- Вес семантического слияния  $\gamma$ : 0,6.
- Параметры усовершенствования YAKE  $\alpha, \beta$ : 0,3, 0,2.

- Частота обновления весов: после каждой пользовательской обратной связи.
- Критерий сходимости суждения: изменение весов в течение 5 раз подряд менее 0,01.

#### 4. РЕЗУЛЬТАТЫ

Анализ полученных в ходе эксперимента результатов показал, что веса признаков для большинства пользователей после быстрых изменений в начальном периоде постепенно стремятся к стабильному состоянию. Для таких пользователей процесс сходимости весов признаков в основном можно разделить на три этапа: период быстрой адаптации (дни 1–8), период оптимизации точности (дни 9–24) и период стабильности весов признаков (дни 25–30). Для небольшого количества пользователей была отмечена задержка процесса сходимости или явления вторичной оптимизации весов признаков, требующие более длительного времени адаптации. Эти результаты показаны на рисунке 2.



**Рис. 2.** Сравнение вариантов сходимости весов признаков для различных типов пользователей

Как видно из рисунка 2:

- Для пользователя А — доминирующий признак “временной” (например, время суток, рабочий/выходной день) — вес доминирующего признака увеличивается с 0,20 до 0,36.
- Для пользователя Б — доминирующий признак “личный” (например, работа, учеба, нагрузка) — вес доминирующего признака после некоторого колебания стабилизировался на 12-й день на уровне 0,41. Стоит отметить, что в период 12–15 дней наблюдалось кратковременное изменение, что может быть связано с изменением содержания обратной связи.
- Для пользователя В — доминирующий признак “окружающей среды” (например, погода, температура, сезон) — вес данного признака сходится к 0,37.

Доминирующий признак — это признак, имеющий наибольший вес, в текущей модели для конкретного пользователя.

**Период быстрой адаптации (дни 1–7):** значения весов признаков быстро изменяются, что подтверждает необходимую начальную настройку модели под индивидуальные особенности каждого пользователя в предоставлении обратной связи. Также стоит отметить, что различные группы пользователей демонстрируют разные тенденции в распределении весов признаков. Система посредством предварительного анализа обратной связи выявляет основные области интереса пользователей.

**Период точной корректировки (дни 8–21):** амплитуда изменений весов признаков постепенно уменьшается. Система посредством незначительных корректировок дополнительно оптимизирует распределение весов признаков. В течение данного периода у отдельных пользователей наблюдалось повторное изменение весов признаков, то есть в период с 8-го по 21-й день происходило небольшое перераспределение весов признаков.

**Период стабильного поддержания (дни 22–30):** график изменения весов признаков становится более плавным. Система достигает относительно стабильной персонализированной конфигурации. Среднее время сходимости составляет 26 дней, при этом самая быстрая сходимость была достигнута за 19 дней, а самая медленная за 30 дней.

Результаты эксперимента показывают, что у большинства пользователей значения весов признаков стабилизируются в течение 30 дней. После стабилизации значения весов признаков отражают индивидуальные особенности обратной связи каждого пользователя. Распределение весов признаков у различных групп пользователей демонстрирует значительные различия, подтверждая необходимость персонализированной адаптации системы.

Для оценки эффективности предложенного метода извлечения признаков и оптимизации их весов было проведено его сравнение с существующими и хорошо зарекомендовавшими себя методами. Результаты сравнения приведены в таблице 2.

**Таблица 2.** Сравнение производительности различных методов

| Метод                      | Точность прогнозирования | Удовлетворенность пользователей (0–5, 0 — не удовлетворен, 5 — полностью удовлетворен) | Среднее время отклика (мс) |
|----------------------------|--------------------------|--|----------------------------|
| Усовершенствованный YAKE   | 0,649                    | 3,5  | 17                         |
| Усовершенствованный TF-IDF | 0,712                    | 3,6  | 43                         |
| Объединение GloVe-FastText | 0,763                    | 4,0  | 71                         |
| RoBERTa-base               | 0,802                    | 4,2  | 1647                       |
| Предлагаемый метод         | 0,784                    | 4,1  | 104                        |

Результаты эксперимента показывают, что описанный в данной работе метод показывает хороший баланс между производительностью и эффективностью. По сравнению с существующими методами предлагаемый в этой статье метод имеет более высокую точность прогнозирования — приблизительно на 23 % выше других методов, и удовлетворенность пользователей на 25 % выше других методов. Сравнение с современными методами глубокого обучения показывает, что хотя методы глубокого обучения имеют преимущества в точности, они сопровождаются проблемами вычислительных расходов.

Результаты экспериментов показывают, что предложенный метод интегрированного извлечения признаков и оптимизации их весов может быть эффективно применён

в системах обработки пользовательской обратной связи, где важна быстрая адаптация модели к новым данным. Несмотря на то, что по точности он немного уступает современным методам глубокого обучения, при комплексной оценке таких параметров, как точность, время отклика и потребление вычислительных ресурсов, предложенный метод демонстрирует более высокую эффективность и практическую применимость.

## 5. ЗАКЛЮЧЕНИЕ

Представленный в статье метод извлечения признаков из пользовательской обратной связи с оптимизацией весов является эффективным решением для динамической адаптации интеллектуальных систем к персонализированным потребностям пользователей. Основными преимуществами метода являются: интеграция усовершенствованного алгоритма YAKE с персонализированным TF-IDF и объединением векторных представлений слов с помощью моделей GloVe-FastText; механизм двунаправленной верификации между пользователем и системой; прямое отображение извлеченных признаков на веса признаков с возможностью многопараметрической оптимизации.

Реализация этого метода в системе оценки эмоциональных состояний продемонстрировала высокую гибкость и потенциал для интеграции в интеллектуальные сервисы, ориентированные на персонализированную адаптацию. Результаты эксперимента с участием 16 пользователей в течение 30 дней подтвердили, что предложенный метод значительно повышает точность прогнозирования эмоциональных состояний и уровень удовлетворенности пользователей по сравнению с традиционными методами.

В дальнейшем предложенный метод может быть расширен для анализа различных типов пользовательской обратной связи и применен в различных областях, включая интеллектуальные пользовательские интерфейсы, системы поддержки принятия решений и персонализированные рекомендательные сервисы. Дальнейшие исследования будут направлены на оптимизацию механизмов обработки обратной связи и совершенствование архитектуры модели для повышения эффективности и расширения сферы применения.

## Список литературы

1. Васюнин М. А., Бахман А. А. Технологии понимания естественного языка // Искусственный интеллект в автоматизированных системах управления и обработки данных: сборник трудов конференции. М.: 2022. С. 269–274.
2. Jannach D., Jugovac M. Measuring the business value of recommender systems // ACM Transactions on Management Information Systems (TMIS). 2019. Vol. 10, № 4. P. 1–23.
3. Tewari A. S., Barman A. G. Collaborative recommendation system using dynamic content based filtering, association rule mining and opinion mining // International Journal of Intelligent Engineering & Systems. 2017. Vol. 10, № 5. P. 57–66.
4. Salton G., Wong A., Yang C. S. A vector space model for automatic indexing // Communications of the ACM. 1975. Vol. 18, № 11. P. 613–620.
5. Rocchio Jr, J. J. Relevance feedback in information retrieval // The SMART retrieval system: experiments in automatic document processing. Englewood Cliffs: Prentice-Hall, 1971. P. 313–323.
6. Нуничук М. М., Намиот Д. Е. Обзор методов построения рекомендательных систем на основе сессий // International Journal of Open Information Technologies. 2023. Т. 11, № 5. С. 22–32.
7. Devlin J., Chang M. W., Lee K., Toutanova K. Bert: Pre-training of deep bidirectional transformers for language understanding // Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies. Minneapolis, 2019. Vol. 1 (long and short papers). P. 4171–4186.

8. Campos R., Mangaravite V., Pasquali A. et al. YAKE! Collection-independent automatic keyword extractor // *Advances in Information Retrieval: proceedings*. Cham: Springer, 2018. P. 806–810.
9. Ruder S. An overview of gradient descent optimization algorithms // arXiv.org. 2016. URL: <https://arxiv.org/abs/1609.04747> (дата обращения: 10.10.2025).
10. Holland J. H. Genetic algorithms // *Scientific American*. 1992. Vol. 267, № 1. P. 66–73.
11. Robertson S., Zaragoza H. The probabilistic relevance framework: BM25 and beyond // *Foundations and Trends® in Information Retrieval*. 2009. Vol. 3, № 4. P. 333–389.
12. Mikolov T., Chen K., Corrado G., Dean J. Efficient estimation of word representations in vector space // arXiv.org. 2013. URL: <https://arxiv.org/abs/1301.3781> (дата обращения: 10.10.2025).
13. Vaswani A., Shazeer N., Parmar N. et al. Attention is all you need // *Advances in neural information processing systems*. 2017. Vol. 30. P. 5998–6008.
14. Pennington J., Socher R., Manning C. D. Glove: Global vectors for word representation // *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*. Doha, 2014. P. 1532–1543.
15. Bojanowski P., Grave E., Joulin A., Mikolov T. Enriching word vectors with subword information // *Transactions of the association for computational linguistics*. 2017. Vol. 5. P. 135–146.

Поступила в редакцию 15.09.2025, окончательный вариант — 10.10.2025.

Ма Даньтин, аспирантка кафедры вычислительной техники СПбГЭТУ «ЛЭТИ»,  
✉ [dantingma65@gmail.com](mailto:dantingma65@gmail.com)

Шичкина Юлия Александровна, доктор технических наук, доцент, профессор кафедры  
вычислительной техники СПбГЭТУ «ЛЭТИ», [strange.y@mail.ru](mailto:strange.y@mail.ru)

---

Computer tools in education, 2026

№ 1: 57–73

<http://cte.eltech.ru>

doi:10.32603/2071-2340-2026-1-57-73

## Hybrid Method for User Feedback Analysis and Dynamic Weight Optimization of Key Parameters in AI Systems

Ma D.<sup>1</sup>, ✉ [dantingma65@gmail.com](mailto:dantingma65@gmail.com), [orcid.org/0009-0004-2021-5145](https://orcid.org/0009-0004-2021-5145)

Shichkina Y. A.<sup>1</sup>, [strange.y@mail.ru](mailto:strange.y@mail.ru), [orcid.org/0000-0001-7140-1686](https://orcid.org/0000-0001-7140-1686)

<sup>1</sup>Saint Petersburg State Electrotechnical University “LETI”,  
Professora Popova ul. 5, building 3, St. Petersburg, 197022, Russian Federation

### Abstract

Understanding user preferences plays a crucial role in personalized services and intelligent systems. This understanding is achieved through feedback mechanisms in various forms, with natural language being the most preferred format. However, this approach requires precise identification of key features from user feedback and dynamic optimization of feature weights to enhance system decision-making accuracy. Traditional methods face significant limitations in extracting key feedback features from natural language texts and adapting weight distribution effectively. This paper presents a novel method for extracting

key features from user feedback and optimizing their weights through preliminary multi-iterative user-AI system interactions. The proposed method integrates four core modules: YAKE-based feature extraction, personalized weight modeling using TF-IDF, semantic fusion of vector representations with feature classification, and dynamic weight distribution for key features. This creates a direct mapping mechanism from user feedback to feature weight sets used in AI decision-making models. The method's novelty lies in developing an enhanced YAKE keyword extraction algorithm with improved semantic and feature density; a TF-IDF weight calculation algorithm incorporating historical user preferences and personalized weighting; a feature classification mechanism based on semantic similarity; and optimized processes for feature extraction and weight distribution. The method was tested using an emotion prediction system with continuous data collection from 16 users over 30 days. Results demonstrate that the proposed method achieves 78.4 % emotion prediction accuracy, representing a 23 % improvement over baseline methods. Significant enhancements in user satisfaction with system predictions and substantial reduction in time to achieve stable feature weight distribution were observed.

**Keywords:** *user feedback; feature extraction; weight optimization; multi-iterative interaction; personalized systems; machine learning; artificial intelligence.*

**Citation:** D. Ma and Y. A. Shichkina, "Hybrid Method for User Feedback Analysis and Dynamic Weight Optimization of Key Parameters in AI Systems," *Computer tools in education*, no. 1, pp. 57–73, 2026 (in Russian); doi:10.32603/2071-2340-2026-1-57-73

## References

1. M. A. Vasyunin and A. A. Bakhman, "Natural language understanding technologies," in *Proc. of Artificial Intelligence in Automated Control and Data Processing Systems, 27-28 Apr. 2022*, Moscow, 2022, pp. 269–274 (in Russian).
2. D. Jannach and M. Jugovac, "Measuring the business value of recommender systems," *ACM Trans. Manag. Inf. Syst.*, vol. 10, no. 4, pp. 1–23, 2019; doi:10.1145/3370082
3. A. S. Tewari and A. G. Barman, "Collaborative recommendation system using dynamic content based filtering, association rule mining and opinion mining," *Int. J. Intell. Eng. Syst.*, vol. 10, no. 5, pp. 57–66, 2017; doi:10.22266/ijies2017.1031.07
4. G. Salton, A. Wong, and C. S. Yang, "A vector space model for automatic indexing," *Commun. ACM*, vol. 18, no. 11, pp. 613–620, 1975; doi:10.1145/361219.361220
5. J. J. Rocchio Jr., "Relevance feedback in information retrieval," in *The SMART Retrieval System: Experiments in Automatic Document Processing*, Englewood Cliffs, NJ, USA: Prentice-Hall, 1971, pp. 313–323.
6. M. M. Ninichuk and D. E. Namiot, "Survey on methods for building session-based recommender systems," *Int. J. Open Inf. Technol.*, vol. 11, no. 5, pp. 22–32, 2023 (in Russian).
7. J. Devlin et al., "BERT: Pre-training of deep bidirectional transformers for language understanding," in *Proc. 2019 Conf. North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, Minneapolis, MN, USA, 2019, vol. 1, pp. 4171–4186; doi:10.18653/v1/N19-1423
8. R. Campos, V. Mangaravite, A. Pasquali, A. Jorge, C. Nunes, and A. Jatowt, "YAKE! Collection-independent automatic keyword extractor," in *Proc. of Advances in Information Retrieval (ECIR)*, Grenoble, France, Springer, Cham., 2018, pp. 806–810; doi: 10.1007/978-3-319-76941-7\_80
9. S. Ruder, "An overview of gradient descent optimization algorithms," 2016. [Online]. Available: <https://arxiv.org/abs/1609.04747>
10. J. H. Holland, "Genetic algorithms," *Sci. Amer.*, vol. 267, no. 1, pp. 66–73, 1992; doi:10.1038/scientificamerican0792-66
11. S. Robertson and H. Zaragoza, "The probabilistic relevance framework: BM25 and beyond," in *Found. Trends Inf. Retrieval*, vol. 3, no. 4, pp. 333–389, 2009; doi:10.1561/1500000019

12. T. Mikolov, K. Chen, G. Corrado, and J. Dean, “Efficient estimation of word representations in vector space,” 2013. [Online]. Available: <https://arxiv.org/abs/1301.3781>
13. A. Vaswani et al., “Attention is all you need,” in *Adv. Neural Inf. Process. Syst. (NeurIPS-2017)*, Long Beach, CA, USA, 2017, vol. 30, pp. 5998–6008.
14. J. Pennington, R. Socher, and C. D. Manning, “GloVe: Global vectors for word representation,” in *Proc. 2014 Conf. Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, 2014, pp. 1532–1543; doi:10.3115/v1/D14-1162
15. P. Bojanowski et al., “Enriching word vectors with subword information,” *Trans. Assoc. Comput. Linguistics*, vol. 5, pp. 135–146, 2017; doi:10.1162/tacl\_a\_00051

*Received 15-09-2025, the final version — 10-10-2025.*

**Danting Ma, Postgraduate, Department of Computer Science and Engineering, Saint Petersburg Electrotechnical University “LETI”, ✉ [dantingma65@gmail.com](mailto:dantingma65@gmail.com)**

**Yulia Shichkina, Doctor of Sciences (Tech.), Docent, Professor at the Department of Computer Science and Engineering, ETU “LETI”, [strange.y@mail.ru](mailto:strange.y@mail.ru)**