

ПРОГНОЗИРОВАНИЕ МОДНЫХ ТРЕНДОВ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Сизова О.В., Сироткина А.С., Рычихина Н.С.

Сизова Ольга Владимировна (ORCID 0000-0002-1443-3566),
Сироткина Анастасия Сергеевна
Ивановский государственный химико-технологический университет,
Россия. 153000, Ивановская область, г. Иваново, пр. Шереметевский, 7.
e-mail: siz-olga@yandex.ru, anastasiaeeva@mail.ru
Рычихина Наталья Сергеевна (ORCID 0000-0001-9872-424X)
Ивановский государственный университет,
Россия. 153025, Ивановская область, г. Иваново, ул. Ермака, д. 39.
e-mail: richihina@mail.ru

Прогнозирование модных трендов остается сложной задачей из-за ограниченного охвата элементов и упрощенных моделей в существующих подходах. В данной работе представлен крупномасштабный датасет FIT, содержащий временные ряды модных элементов и демографические данные пользователей. Для анализа сложных временных зависимостей предложена модель KERN на основе рекуррентных нейронных сетей, учитывающая внутренние и внешние знания предметной области. Модель продемонстрировала точные прогнозы даже для элементов с нерегулярными паттернами как на полу-годовом, так и на годовом горизонте планирования. Особый интерес представляет анализ различий в тенденциях для разных пользовательских групп – модель успешно улавливает эти особенности, что значительно повышает точность персонализированных прогнозов. На основе этих результатов разработана система генерации комплексных отчетов, охватывающих все аспекты модных тенденций от базовых категорий до специфических атрибутов. Эксперименты подтверждают, что KERN обеспечивает более точное прогнозирование трендов по сравнению с традиционными методами.

Ключевые слова: модные тренды, крупномасштабный датасет, модель KERN, прогнозирование, глубокое обучение, рекуррентные нейронные сети, анализ временных рядов

FORECASTING FASHION TRENDS BASED ON NEURAL NETWORKS

Sizova O.V., Sirotkina A.S., Rychikhina N.S.

Sizova Olga Vladimirovna (ORCID 0000-0002-1443-3566),
Sirotkina Anastasia Sergeevna,
Ivanovo State University of Chemistry and Technology,
Russia. 153000, Ivanovo region, Ivanovo, Sheremetevskyave., 7.
E-mail: siz-olga@yandex.ru, anastasiaeeva@mail.ru
Rychikhina Nataly Sergeevna (ORCID 0000-0001-9872-424X)
Ivanovo State University,
Russia. 153025, Ivanovo region, Ivanovo, st. Ermak, 39.
E-mail: richihina@mail.ru

Fashion trend forecasting remains a challenging task due to the limited item coverage and simplified models in existing approaches. In this paper, a large-scale FIT dataset containing time series of fashion items and user demographics is presented. To analyze complex time dependencies, a recurrent neural network-based KERN model is proposed that takes into account internal and external domain knowledge. The model demonstrates accurate forecasts even for items with irregular patterns on both semi-annual and annual planning horizons. Of particular interest is the analysis of differences in trends for different user groups; the model successfully captures these features, which significantly improves the accuracy of personalized forecasts.

Based on these results, a comprehensive report generation system is developed that covers all aspects of fashion trends from basic categories to specific attributes. Experiments confirm that KERN provides more accurate trend forecasting compared to traditional methods.

Keywords: fashion trends, large-scale dataset, KERN model, forecasting, deep learning, recurrent neural networks, time series analysis

ВВЕДЕНИЕ

Развитие текстильной промышленности является для Российской Федерации одной из важных задач, т.к. страна имеет большой опыт и все необходимые ресурсы, являющиеся фундаментом успеха развития данной отрасли. Поддержка государства, которое ставит целью цифровой трансформации обрабатывающих отраслей промышленности обеспечение технологической независимости, возможность коммерциализации российских исследований и разработок, а также ускорение технологического развития российских компаний и обеспечение конкурентоспособности разрабатываемых ими продуктов, дает предприятиям легкой промышленности дополнительные возможности [1].

Для реализации этой задачи необходимо продвигать молодые российские бренды, формируя имидж доступных, безопасных и качественных товаров. Повышение конкурентоспособности российских брендов в сочетании с цифровой трансформацией бизнеса даст возможность предприятиям текстильной промышленности и отрасли в целом перейти на устойчивый путь развития и существенно повысить свой вклад в общий объем производства в стране [2].

Основное отличие текстильной отрасли от других отраслей заключается в преобладающем влиянии моды, диктате потребительского спроса и постоянном обновлении модельного ряда, а часто и ассортимента. Для современного производства особенно важно сокращение времени вывода новых изделий на рынок при одновременном удовлетворении постоянно меняющихся специфических потребностей потребителей [3, 4].

Сегодня мода – одна из доминирующих форм культурных практик, культурная индустрия, создающая собственные технологии коммуникаций и особый тип медиапродукта, механизм реализации социальных потребностей [5, 6].

Суть моды заключается в изменчивости, что делает прогнозирование модных тенденций важнейшей задачей для индустрии [7].

Традиционные методы, основанные на субъективных оценках экспертов, анализирующих культурные явления и поведение потребителей, обладают существенными ограничениями в виде

низкой надежности и высокой вариативности [8]. Современные цифровые технологии открывают новые возможности для объективного прогнозирования через анализ больших данных, особенно из социальных сетей, где ежедневно генерируется огромный объем модного контента [9, 10].

Целью данной работы является применение нейронных сетей для прогнозирования модных трендов.

Модные тренды – это внешний вид и конструирование модных продуктов во время определённого сезона. Тренды дают представление о стиле и цвете, которые будут использованы в окончательном варианте модных изделий [11].

Исследования в области моды охватывают такие задачи, как распознавание, поиск, комбинирование стилей и виртуальная примерка [12-16]. Анализ и прогнозирование трендов остаются ключевыми направлениями из-за их важности для индустрии.

Синьтун Хань и др. [17] предложили метод автоматического выявления паттернов на неделях моды. Уткарш Малл и др. [18] расширили анализ, включив данные с подиумов и из реальной жизни Фули Фэн и др. [19] изучили тренды через статистику социальных медиа. Зиад Аль-Халах и др. [20] использовали NMF и экспоненциальное сглаживание для прогнозирования, но их стили были ограничены визуальными кластерами. Юньшань Ма и др. [21] анализировали конкретные элементы (напр., наличие шляпы), но не охватывали сложные паттерны.

Анализ данных работ показал, что авторы либо фокусируются на статистике, либо предсказывают простые тренды, оставляя более сложные элементы без внимания.

Прогнозирование модных трендов связано с анализом временных рядов. Традиционные методы (AR, MA, ARIMA) эффективны для данных с сезонностью, но хуже справляются с волатильными сигналами.

Глубокие нейросети, особенно LSTM, показывают лучшие результаты в NLP, распознавании речи и прогнозировании. Использование доменных знаний улучшает прогнозирование в других областях (например, прогноз акций), однако в моде такие подходы пока недостаточно изучены.

В данной работе предлагается инновационный подход к прогнозированию модных тенденций с использованием рекуррентных нейронных сетей, обогащенных знаниями о взаимосвязях между элементами моды. Таким образом, проведенное исследование направлено на создание научно обоснованного подхода к прогнозированию модных трендов для повышения удовлетворенности клиентов и обеспечения высокой точности и адаптивности.

МАТЕРИАЛЫ И МЕТОДЫ

Данное исследование посвящено прогнозированию модных трендов, целью которого является предсказание будущей популярности каждого элемента моды (например, белый цвет, платье, открытые плечи и т. д.) для конкретных пользовательских групп (например, женщины 18–25 лет из Лондона).

Для каждого элемента моды $f \in F$ и группы пользователей $g \in G$ временная популярность f для g определяется как временной ряд:

$$y^g_f = (y_1, \dots, y_t, \dots),$$

где: F – множество всех элементов моды,

G – множество всех пользовательских групп. Значение временного ряда в момент времени t вычисляется как:

$$y_t = N^{g,f}_t / N^g_t,$$

где: $N^{g,f}_t$ – количество элементов моды f в момент t для группы g , N^g_t – общее количество модных предметов (одежда, сумки, обувь и т. д.) в момент t для группы g .

Имея исторические данные за период $[1, T]$, задача состоит в прогнозировании значений на будущий интервал $[T + 1, T + T']$,

где: T – длина исторической последовательности,

T' – горизонт прогнозирования (количество шагов вперед, $T' > 1$).

Существующие наборы данных кроме FIT [22] и GeoStyle [23] не позволяют проводить исследования подобного рода, поэтому был создан новый датасет на основе публикаций из социальных сетей. За основу взяты данные FIT и GeoStyle. Для формирования датасета осуществлен сбор миллионов публикаций пользователей по всему миру. Проведена многоэтапная фильтрация данных с использованием автоматизированных и ручных методов, аналогичных подходам, описанным в работах [24, 25]. На первом этапе применены предобученные модели детекции человеческого тела и лиц, что позволило исключить изображения без людей или с аномальными пропорциями. Дополнительно отфильтрованы публикации, содержащие изображения других людей, а не владельцев аккаунтов. В результате сформирована финальная выборка, включающая около 880 тысяч изображений.

Полученный набор данных характеризуется расширенной информацией о пользователях, более богатым набором модных элементов и увеличенным временным охватом по сравнению с имеющимися аналогами.

Аннотирование данных выполнено по двум ключевым направлениям: пользовательские характеристики и элементы моды. Для классификации пользователей собраны данные о возрасте, поле и местоположении. С использованием готовых детекторов [26, 27] определены доминирующий пол и средний возраст каждого пользователя на основе анализа всех его публикаций, при этом противоречивые результаты исключены из рассмотрения.




Рис. 1. Сеть рекуррентных знаний с расширенными возможностями

Fig. 1. The Knowledge Enhanced Recurrent Network (KERN)

Возрастные группы разделены на четыре категории: 0-18, 18-25, 25-40 и старше 40 лет. Геолокация установлена по наиболее часто встречающимся координатам публикаций, что позволило выделить 14 крупных городов мира. Комбинация указанных параметров дала возможность сформировать 73 пользовательские группы.

Для выделения элементов моды использован специализированный инструмент тегирования, позволивший идентифицировать 187 характеристик, разделенных на три категории: типы одежды, атрибуты и стили. Каждое изображение в наборе данных содержит информацию о пользовательской группе, временной метке и связанных элементах моды. Такой подход обеспечивает комплексное представление о динамике модных предпочтений различных демографических групп.

Для моделирования сложных временных зависимостей в данных предложена архитектура Knowledge Enhanced Recurrent Network (KERN), основанная на LSTM-сетях типа encoder-decoder (рис. 1). Для прогнозирования модных тенденций используется LSTM-модель "кодировщик-декодировщик", которая объединяет временные ряды и последовательную информацию в единую модель.

1. Входные данные и эмбединги

Каждая последовательность продаж ss описывается двумя компонентами:

- Группа g : описывает целевую аудиторию (контекст продаж).

- Элемент моды f : описывает предмет одежды.

Группа $g = [c, a, n]$

Группа формируется из категориальных признаков:

- c : Город (City), где произошла продажа.
- a : Возрастная группа (Age) покупателя (напр., 18-25).

- n : Пол покупателя (Gender, напр., Female).

Каждый категориальный признак преобразуется в плотный вектор (эмбединг):

- $c \in \mathbb{R}^D$: векторное представление города.

- $a \in \mathbb{R}^D$: векторное представление возрастной группы.

- $n \in \mathbb{R}^D$: векторное представление пола.

Затем эти эмбединги конкатенируются $[c, a, n]$ и пропускаются через полносвязный слой (FC), чтобы получить итоговое векторное представление группы:

$$g = W_g [c, a, n] + b_g,$$

где: $W_g \in \mathbb{R}^{3D \times D}$ – матрица весов полносвязного слоя, $b_g \in \mathbb{R}^D$ – вектор смещения, $D_g \in \mathbb{R}^D$ – итоговый эмбединг группы.

Элемент моды f :

- f : Атрибут товара (напр., "Платье" – Dress). На изображении показано, что у товара может быть своя таксономия (дерево категорий → атрибутов → значений).

- $f \in \mathbb{R}^D$: Векторное представление элемента моды, полученное через слой эмбедингов.

2. Кодировщик (LSTM Encoder)

Назначение: Прочитать исторические данные временного ряда и сжать их в последовательность скрытых состояний, которые encapsulate информацию о прошлом.

- Вход на шаге t : $v_t^e = [g, f, m_t, y_t]$

- $g \in \mathbb{R}^D$: Эмбединг группы (постоянный для всей последовательности).

- $f \in \mathbb{R}^D$: Эмбединг элемента моды (постоянный для всей последовательности).

- $m_t \in \mathbb{R}^D$: Временной эмбединг (Time embedding) для метки времени t (например, день недели, месяц).

- y_t : Наблюдаемое значение временного ряда (например, объем продаж) на шаге t .

- Скрытое состояние на шаге t

$$h_t^e = LSTM_e(v_t^e; h_{t-1}^e),$$

где $h_t^e \in \mathbb{R}^H$ – скрытое состояние кодировщика на временном шаге t .

3. Декодировщик (BiLSTM Decoder)

Назначение: спрогнозировать будущие значения временного ряда, используя финальное состояние кодировщика как контекст.

- Инициализация: начальное скрытое состояние декодировщика инициализируется последним скрытым состоянием кодировщика: $h_0^d = h_t^e$.

- Вход на шаге t : $v_t^d = [g, f, m_t]$

В отличие от кодировщика, здесь нет доступа к реальному значению y_t , так как мы прогнозируем будущее.

- Скрытое состояние на шаге t : используется двунаправленный LSTM (BiLSTM)

$$\overrightarrow{h}_t^d = LSTM_d(v_t^d; \overrightarrow{h}_{t-1}^d) \text{ (прямой подход)}$$

$$\overleftarrow{h}_t^d = LSTM_d(v_t^d; \overleftarrow{h}_{t-1}^d) \text{ (обратный подход)}$$

$h_t^d = [\overrightarrow{h}_t^d, \overleftarrow{h}_t^d]$ конкатенированное скрытое состояние декодировщика

- Прогноз на шаге t :

$$\widehat{y}_t^e = W_e h_t^e + b_e,$$

(выход кодировщика, реконструкция прошлого)

$$\widehat{y}_t^d = W_d h_t^d + b_d,$$

(выход декодировщика, прогноз будущего) где W_e, W_d – матрицы весов, b_e, b_d – смещения.

4. Функция потерь и регуляризация

Основная функция потерь: сумма ошибок восстановления истории кодировщиком и ошибок прогноза декодировщиком.

$$L_{LSTM} = L_e(y^e, y^{e*}, \theta_e) + L_d(y^d, y^{d*}, \theta_d),$$

где: y^{e*}, y^{d*} – истинные значения (ground truth) для encoder и decoder, θ_e, θ_d – параметры encoder и decoder, L_e, L_d – функции потерь (например, MSE).

5. Таксономия элементов моды (Element Relation Module)

Для улучшения представлений элементов моды f используется knowledge graph в виде дерева таксономии (Категория → Атрибут → Значение, напр., "Одежда" → "Верх" → "Платье").

Между узлами графа происходит передача сообщений (message passing):

1. Сообщение для узла i вычисляется как взвешенная сумма представлений его соседей N_i

$$m_i = \sum_{j \in N_i} w_j \times f_j.$$

2. Представление узла i обновляется, ассимилируя полученное сообщение

$$f_i \leftarrow f_i + m_i.$$

Этот процесс позволяет эмбедингу товара f_i обогащаться информацией о его родительских категориях и соседних атрибутах, что улучшает его семантическое представление.

Данная модель уникальным образом интегрирует два типа знаний: внутренние, отражающие сходства между временными рядами различных модных элементов через механизм триплет-регуляризации, и внешние, кодирующие таксономические связи между элементами моды через процедуру message passing. Такой подход позволяет учитывать как автономную динамику отдельных трендов, так и их взаимное влияние, например корреляцию между популярностью свитеров и водолазок. Дополнительно модель использует семантические представления пользовательских групп для персонализации прогнозов. Основные исследовательские вопросы включают сравнение модели KERN с современными методами прогнозирования, оценку влияния модулей

отношений и анализ работы модели для конкретных элементов моды. Экспериментальная установка использует разные временные периоды для входных и прогнозируемых данных. Для GeoStyle берутся данные за 1 год (52 точки) для прогноза на 0.5 года (26 точек). Для FIT рассматриваются два варианта: прогноз на 0,5 года (12 точек) и 1 год (24 точки) на основе двухлетних входных данных (48 точек). Поскольку GeoStyle содержит только информацию о городах, групповое представление упрощается до эмбединга города.

Применяется стратегия скользящего окна для генерации обучающих и тестовых выборок. Основные метрики оценки – средняя абсолютная ошибка (MAE) и средняя абсолютная процентная ошибка (MAPE) [28, 29].

В реализации используются эмбединги размерностью 50 для всех признаков (возраст, пол, город, элементы моды, время). Гиперпараметр регуляризации λ устанавливается равным 3×10^{-4} . Обучение проводится на батчах из 450 временных рядов. Тестирование выполняется раздельно на четных и нечетных точках данных для валидации и окончательной оценки соответственно [30, 31].

Для сравнения выбраны современные методы прогнозирования временных рядов, включая простые методы (Mean, Last), авторегрессионные модели (AR, VAR), экспоненциальное сглаживание (ES), а также специализированные методы для модных тенденций (Linear and Cyclic, Geostyle). Модель Geostyle, сочетающая линейную и циклическую компоненты, рассматривается как текущий state-of-the-art метод для набора данных GeoStyle.

РЕЗУЛЬТАТЫ

В работе было осуществлено обучение модели на данных за 2016-2019 годы. На вход модели поступала выборка 2016-2018 годов. Валидация осуществлялась на данных за 2018-2019 годы.




Рис. 2. Сравнение предсказаний моделей KERN и KERN-IE
Fig. 2. Comparison of predictions of KERN and KERN-IE models

Таблица 1

Сравнение эффективности модели KERN с базовыми методами прогнозирования модных тенденций
Table. 1. Comparison of the effectiveness of the KERN model with the basic methods of forecasting fashion trends

Метод	GeoStyle (полгода)		FIT (полгода)		FIT (год)	
	MAE	MAPE	MAE	MAPE	MAE	MAPE
Mean	0.0232	25.79	0.132	65.32	0.145	63.21
Last	0.0216	21.04	0.125	46.35	0.148	54.04
AR	0.0211	20.69	0.114	54.32	0.119	51.96
VAR	0.0152	17.95	0.157	62.87	0.123	47.35
ES	0.0218	20.59	0.133	54.29	0.151	57.42
Linear	0.0395	24.40	0.112	43.34	0.143	45.89
Cyclic	0.0155	16.64	0.129	48.93	0.147	51.66
GeoStyle	0.0139	16.03	0.136	51.40	0.139	53.14
KERN	0.0133	14.24	0.083	30.22	0.097	33.45
Улучшение (%)	10.89	11.17	25.89	30.87	22.01	27.11

На рис. 2 представлены результаты прогнозирования белого цвета и предмета одежды leggings для двух моделей – KERN (с внутренними и внешними знаниями) и KERN-IE (без внутренних и внешних знаний). В табл. 1 представлен сравнительный анализ эффективности модели KERN с базовыми методами прогнозирования модных тенденций (чем меньше значения, тем лучше). Результаты представлены для прогнозов, полученных при обучении на данных за полгода и год. Ключевые наблюдения:

1. Модель KERN демонстрирует стабильно лучшие результаты на обоих наборах данных при всех экспериментальных настройках.

На GeoStyle достигаются значения MAE ниже 0.011 и MAPE ниже 15. На FIT показатели MAE остаются ниже 0.1, а MAPE около 31, что значительно превосходит базовые методы.

2. На наборе FIT преимущество KERN особенно заметно благодаря:

- учету более детализированных элементов моды;
- обработке сложных временных паттернов;
- использованию LSTM-архитектуры и доменных знаний.

3. Большинство методов, включая KERN, показывают более высокую точность при прогнозировании на полгода по сравнению с годовым прогнозом на FIT. Это объясняется возрастающей сложностью долгосрочного прогнозирования.

На рис. 3 представлены результаты прогноза для разных демографических групп (географическое положение, пол, возраст).

В табл. 2 представлена оценка вклада различных типов знаний в модель KERN по результатам оценки MAE.

Таблица 2

Вклад различных типов знаний в модель KERN
Table.2. Contribution of different types of knowledge to the KERN model

Конфигурация	GeoStyle (полгода)	FIT (полгода)	FIT (год)
KERN-IE (без внутренних и внешних знаний)	0.0124	0.0870	0.0976
KERN-E (без внешних знаний)	-	0.0827	0.0983
KERN-I (без внутренних знаний)	0.0139	0.0837	0.0932
KERN	0.0102	0.0821	0.0921

Экспериментальная оценка влияния различных типов знаний на качество прогнозирования выявила ключевые закономерности. Внутренние знания о сходстве между элементами, реализованные через триплетную регуляризацию, и внешние знания из таксономии, применяемые для обновления векторных представлений, продемонстрировали значимый вклад в точность модели. Сравнительный анализ модификаций KERN-I (без внутренних знаний), KERN-E (без внешних знаний) и KERN-IE (без обоих компонентов) под

твердил, что исключение любого типа знаний снижает качество прогноза, особенно заметное при долгосрочном прогнозировании на сложных данных. Визуализация результатов на конкретных примерах наглядно показала преимущество полной версии модели при работе со сложными временными паттернами. На рис. 4 представлены результаты прогноза модных трендов на июль 2025 года для женщин Парижа. Отчет составлен на основе анализа данных за период с июля 2023 по июнь 2025 с использованием модели KERN.




Рис. 3. Примеры прогноза для разных демографических групп
Fig. 3. Examples of forecasts for different demographic groups



Рис. 4. Прогноз модных трендов на июль 2025 года для женщин Парижа
Fig. 4. Fashion Trends Forecast for July 2025 for Paris Women

Результаты тестирования модели на шести ключевых категориях модных элементов подтвердили ее высокую эффективность. Модель продемонстрировала точные прогнозы даже для элементов с нерегулярными паттернами как на полугодовом, так и на годовом горизонте планирования. Особый интерес представляет анализ различий в тенденциях для разных пользовательских групп – модель успешно улавливает эти особенности, что значительно повышает точность персонализированных прогнозов. На основе этих результатов разработана система генерации комплексных отчетов, охватывающих все аспекты модных тенденций от базовых категорий до специфических атрибутов.

ВЫВОДЫ

Экспериментальная оценка, проведенная на датасетах FIT и GeoStyle, продемонстрировала превосходство KERN над традиционными методами (ARIMA, матричная факторизация) и базовыми рекуррентными архитектурами. Модель показала способность точно колебания, так и долгосрочные тренды, подтверждая эффективность предложенного подхода. Особое внимание в исследовании было уделено интерпретируемости результатов. Исследование показало, что анализ выявленных взаимосвязей между элементами моды хорошо согласуется с экспертной оценкой, что повышает доверие к модели.

ЛИТЕРАТУРА

1. Распоряжение Правительства Российской Федерации от 6 ноября 2021 г. № 3142-р Стратегическое направление в области цифровой трансформации обрабатывающих отраслей промышленности. <http://static.government.ru/media/files>.
2. Ларионов В.Г., Шереметьева Е.Н., Балановская А.В. Векторы цифровой трансформации текстильной промышленности. *Известия высших учебных заведений. Технология текстильной промышленности*. 2022. № 2(398). С. 12–20. DOI 10.47367/0021-3497_2022_2_12.
3. Мочалина Д. Р., Синева Д.В. Использование нейросетей в разработке коллекций легкой промышленности. *Костюмология*. 2024. Т. 9. № 2. <https://kostumologiya.ru/PDF/01TLKL224.pdf>.
4. Саиди Д.Р., Махмудова Ф.М. Преимущества цифровизации легкой. *Universum: Технические науки: электрон. научн. журн.* 2020, № 1(70). С.108-116.
5. Шумский А.В. Индустрия моды в цифровую эпоху: тренды и технологии. *Меди@льманах*. 2021. №4 (105). С. 60-69. DOI: 10.30547/mediaalmanah.4.2021.6069.
6. Акинина П.С. Специфика дискурса моды. *Colloquium-journal*. 2019. №10 (34). С. 111-112. DOI: 10.24411/2520-6990-2019-10285.
7. Ержанова М.Е., Сугурова Л.А., Джанузакова Р.Ж., Исакулова Ж.А., Абильдаева А.С. Искусственный интеллект в производстве и текстильной промышленно-

Разработанная модель KERN подтвердила свою эффективность, показав значительное преимущество перед современными аналогами. Ключевым фактором успеха стало комбинированное использование внутренних и внешних знаний, обеспечившее улучшение показателей точности на 10-30%. Перспективные направления дальнейших исследований включают расширение набора пользовательских характеристик, интеграцию дополнительных источников экспертных знаний и совершенствование методов обработки мультимодальных данных. Эти усовершенствования позволят вывести точность прогнозирования модных тенденций на новый уровень и расширить практические возможности применения модели в индустрии моды.

Настоящее исследование вносит значительный вклад в развитие методов машинного обучения для модной индустрии, предлагая переход от субъективных экспертных оценок к дата-ориентированному прогнозированию.

Практическая значимость заключается в создании инструмента, способного поддерживать стратегические решения дизайнеров, ритейлеров и маркетологов на основе объективного анализа актуальных тенденций.

Авторы заявляют об отсутствии конфликта интересов, требующего раскрытия в данной статье.

The authors declare the absence a conflict of interest warranting disclosure in this articl.

REFERENCES

1. Decree of the Government of the Russian Federation dated November 6, 2021 N 3142-r Strategic direction in the field of digital transformation of manufacturing industries. <http://static.government.ru/media/files>.
2. Larionov V.G., Sheremetyeva E.N., Balanovskaya A.V. Vectors of digital transformation of the textile industry. *News of higher educational institutions. Technology of the textile industry*. 2022. N 2(398). P. 12-20. DOI 10.47367/0021-3497_2022_2_12. EDN LQOWEU.
3. Mochalina D.R., Sineva D.V. The use of neural networks in the development of light industry collections. *Costumology*. 2024. V. 9. N 2. <https://kostumologiya.ru/PDF/01TLKL224.pdf>.
4. Saidi D.R., Makhmudova F.M. Advantages of light digitalization. *Universum: Technical Sciences: electron. scientific Journal* 2020, N 1(70). P.108-116.
5. Shumsky A.V. Fashion industry in the digital age: trends and technologies. *Copper@lmanakh*. 2021. N 4 (105). P. 60-69. DOI: 10.30547/mediaalmanah.4.2021.6069.
6. Akinina P.S. The specifics of fashion discourse. *Colloquium-journal*. 2019. N 10 (34). P. 111-112. DOI: 10.24411/2520-6990-2019-10285.
7. Yerzhanova M.E., Sugurova L.A., Dzhanzakova R.Zh., Isakulova Zh.A., Abildaeva A.S. Artificial intelligence in manufacturing and the textile industry. *Izvestiya vuzov. Technology of the textile industry*. 2020. N 2(386). P. 150-153.

- сти. *Известия вузов. Технология текстильной промышленности*. 2020. № 2(386). С. 150–153.
8. Деметьева И.Н. Теоретико-методологические подходы к изучению потребительского поведения. *Проблемы развития территории*. 2018. №1 (93). С. 122–132.
9. Щекотин Е.В. Цифровые следы как новый источник данных о качестве жизни и благополучии: обзор современных тенденций. *Вестн. Том. гос. ун-та*. 2021. № 467. С. 170–181. DOI: 10.17223/15617793/467/21.
10. Богданов М.Б., Смирнов И.Б. Возможности и ограничения цифровых следов и методов машинного обучения в социологии. *Мониторинг*. 2021. № 1. С. 304–328. <https://doi.org/10.14515/monitoring.2021.1.1760>.
11. Полякова С.А. Методы прогнозирования моды. *Актуальные исследования*. 2023. №3 (133). <https://apni.ru/article/5367-metodi-prognozirovaniya-modi>.
12. Соболева Л.А., Кузьмин А.Г., Тюрин И.Н., Ташпулатов С.Ш., Белгородский В.С. Технология виртуальной примерки в современном ритейле модной одежды. *Костюмология*. 2021. Т. 6. № 4. <https://kostumologiya.ru/PDF/22IVKL421.pdf>.
13. Yunshan Ma, Xun Yang, Lizi Liao, Yixin Cao, and Tat-Seng Chua. Automatic Fashion Knowledge Extraction from Social Media. MM '19: Proceedings of the 27th ACM International Conference on Multimedia. 2019. P. 2223–2224. <https://doi.org/10.1145/3343031.3350607>.
14. Henrique A.S. Classifying Garments from Fashion-MNIST Dataset Through CNNs. *Advances in Science, Technology and Engineering Systems Journal*. 2021. V. 6. N 1. P. 989–994.
15. Захарова О.И., Шамрин Д.А. Сравнительный анализ методов распознавания образов. *Вестник науки*. 2024. № 6 (75). С.1517–1524.
16. Панасенко С.В., Безпалов В.В., Стар И.А. Интеграция возможностей технологии виртуальной примерки для совершенствования продаж в индустрии моды. *Вестник Алтайской академии экономики и права*. 2024. № 3 (часть 1). С. 106–111.
17. Xintong Han, Zuxuan Wu, Zhe Wu, Ruichi Yu, Larry S. Davis VITON: An Image-Based Virtual Try-On Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2018. P. 7543–7552.
18. Utkarsh Mal, Kevin Matzen, Bharath Hariharan, Noah Snavely, Kavita Bala. Geo Style: Discovering Fashion Trends and Events. *Proceedings of the IEEE International Conference on Computer Vision*. 2019. P. 411–420. DOI Bookmark: 10.1109/ICCV.2019.00050.
19. Fuli Feng, Xiangnan He, Xiang Wang, Cheng Luo, Yiqun Liu, Tat-Seng Chua Temporal Relational Ranking for Stock Prediction. *ACM Transactions on Information Systems*. 2019. V. 37. N 2. P. 1–30.
20. Ziad Al-Halah, Stiefelhagen R., Grauman K. Fashion Forward: Forecasting Visual Style in Fashion. *IEEE International Conference. Art, Computer Science*. 2017. P. 388–397. DOI:10.1109/ICCV.2017.50.
21. Yunshan Ma, Xun Yang, Lizi Liao, Yixin Cao, Tat-Seng Chua. Who, where, and what to wear? extracting fashion knowledge from social media. *Proceedings of the 27th ACM International Conference on Multimedia*. 2019. P. 257–265.
22. Fashion Trend Dataset. Kaggle. <https://www.kaggle.com/datasets/fashionworlddd/fashion-trend-dataset>
23. Yunshan Ma, Lizi Liao, Tat-Seng Chua. Automatic fashion knowledge extraction from social media. *Proceedings of the 27th ACM International Conference on Multimedia*. 2019. P. 2223–2224.
24. Bredikhin A.I. Learning algorithms for convolutional neural networks. *Bulletin of the SOUTH*. 2019. N 1 (52). P. 41–54.
8. Dementieva I.N. Theoretical and methodological approaches to the study of consumer behavior. *Problems of territory development*. 2018. N 1 (93). P. 122–132.
9. Shchekotin E.V. Digital footprints as a new source of data on quality of life and well-being: an overview of current trends. *Vestn. Volume of the State University*. 2021. N 467. P. 170–181. DOI: 10.17223/15617793/467/21.
10. Bogdanov M. B., Smirnov I.B. The possibilities and limitations of digital footprints and machine learning methods in sociology. *Monitoring*. 2021. N 1. P. 304–328. <https://doi.org/10.14515/monitoring.2021.1.1760>.
11. Polyakova S.A. Methods of fashion forecasting. *Current research*. 2023. N 3 (133). <https://apni.ru/article/5367-metodi-prognozirovaniya-modi>.
12. Soboleva L.A., Kuzmin A.G., Tyurin I.N., Tashpulatov S Sh., Belgorodsky V S. Technology of virtual fitting in modern fashion retail. *Costumology*. 2021. V. 6. N 4. <https://kostumologiya.ru/PDF/22IVKL421.pdf>.
13. Yunshan Ma, Xun Yang, Lizi Liao, Yixin Cao, and Tat-Seng Chua. Automatic Fashion Knowledge Extraction from Social Media. MM '19: Proceedings of the 27th ACM International Conference on Multimedia. 2019. P. 2223–2224. <https://doi.org/10.1145/3343031.3350607>.
14. Henrique A.S. Classifying Garments from Fashion-MNIST Dataset Through CNNs. *Advances in Science, Technology and Engineering Systems Journal*. 2021. V. 6. N 1. P.989–994.
15. Zakharova O.I., Shamrin D.A. Comparative analysis of pattern recognition methods. *Bulletin of Science*. 2024. N 6 (75). P.1517–1524.
16. Panasenko S.V., Bezpalov V.V., Star I.A. Integration of virtual fitting technology capabilities to improve sales in the fashion industry. *Bulletin of the Altai Academy of Economics and Law*. 2024. N 3 (part 1). P. 106–111.
17. Xintong Han, Zuxuan Wu, Zhe Wu, Ruichi Yu, Larry S. Davis VITON: An Image-Based Virtual Try-On Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2018. P. 7543–7552.
18. Utkarsh Mal, Kevin Matzen, Bharath Hariharan, Noah Snavely, Kavita Bala. Geo Style: Discovering Fashion Trends and Events. *Proceedings of the IEEE International Conference on Computer Vision*. 2019. P. 411–420. DOI Bookmark: 10.1109/ICCV.2019.00050.
19. Fuli Feng, Xiangnan He, Xiang Wang, Cheng Luo, Yiqun Liu, Tat-Seng Chua Temporal Relational Ranking for Stock Prediction. *ACM Transactions on Information Systems*. 2019. V. 37. N 2. P. 1–30.
20. Ziad Al-Halah, Stiefelhagen R., Grauman K. Fashion Forward: Forecasting Visual Style in Fashion. *IEEE International Conference. Art, Computer Science*. 2017. P. 388–397. DOI:10.1109/ICCV.2017.50.
21. Yunshan Ma, Xun Yang, Lizi Liao, Yixin Cao, Tat-Seng Chua. Who, where, and what to wear? extracting fashion knowledge from social media. *Proceedings of the 27th ACM International Conference on Multimedia*. 2019. P. 257–265.
22. Fashion Trend Dataset. Kaggle. <https://www.kaggle.com/datasets/fashionworlddd/fashion-trend-dataset>
23. Yunshan Ma, Lizi Liao, Tat-Seng Chua. Automatic fashion knowledge extraction from social media. *Proceedings of the 27th ACM International Conference on Multimedia*. 2019. P. 2223–2224.
24. Bredikhin A.I. Learning algorithms for convolutional neural networks. *Bulletin of the SOUTH*. 2019. N 1 (52). P. 41–54.

24. **Бредихин А.И.** Алгоритмы обучения сверточных нейронных сетей. *Вестник ЮГУ*. 2019. № 1 (52). С. 41–54.
25. **Парасич А.В., Парасич В.А., Парасич И.В.** Формирование обучающей выборки в задачах машинного обучения. Обзор. *Информационно-управляющие системы*. 2021. №4 (113). С. 61-70. DOI:10.31799/1684-8853-2021-4-61-70.
26. **Joseph Redmon, Ali Farhadi.** Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767.2018. <https://arxiv.org/pdf/1804.02767>.
27. **Сизова О.В., Тезин Н.К.** Прогнозирование трафика просмотров новостного ресурса методами искусственного интеллекта. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2023. № 4(58). С. 79 - 88. DOI10.6060/ivecofin. 2023584.667.
28. **Павлова Е.А. Сизова О.В.** Анализ и оптимизация on-line продаж торговой организации. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2024. № 4(62). С. 88-97. DOI 10.6060/ivecofin. 2024624.
29. **Ксенофонтова О.Л., Миролюбова А.А., Фокин С.А.** Использование методов интеллектуального анализа данных в банковской сфере. *Современные наукоёмкие технологии. Региональное приложение*. 2023. № 4(76). С. 76-83. DOI 10.6060/snt.20237604.00010.
30. **Бобков, С.П., Астраханцева И.А., Кутузова А.С.** Имитационное моделирование поведения субъектов в сложной социальной системе. *Современные наукоёмкие технологии. Региональное приложение*. 2022. № 4(72). С. 33-39. DOI 10.6060/snt.20227204.0005.
25. **Parasich A.V., Parasich V.A., Parasich I.V.** Formation of a training sample in machine learning tasks. *Review. Information management systems*. 2021. N 4 (113). P. 61-70. DOI:10.31799/1684-8853-2021-4-61-70.
26. **Joseph Redmon, Ali Farhadi.** Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767. 2018. <https://arxiv.org/pdf/1804.02767>.
27. **Sizova O.V., Tezin N.K.** Forecasting the traffic of news resource views using artificial intelligence methods. *Ivecofin*.2023. N 4(58). P. 79-88. DOI 10.6060/ivecofin. 2023584.667.
28. **Pavlova E.A. Sizova O.V.** Analysis and optimization of on-line sales of a trade organization. *Ivecofin*.2024. N 4(62). P. 88-97. DOI 10.6060/ivecofin.2024624.706.
29. **Ksenofontova O.L., Mirolyubova A.A., Fokin S.A.** The use of data mining methods in the banking sector. *Modern high technology. Regional application*. 2023. N 4(76). P. 76-83. DOI 10.6060/snt.20237604.00010.
30. **Bobkov, S.P., Astrakhantseva I.A., Kutuzova A.S.** Simulation modeling of subjects' behavior in a complex social system. *Modern high technology. Regional application*. 2022. N 4(72). P. 33-39. DOI 10.6060/snt.20227204. 0005.

Поступила в редакцию (Received): 14.05.2025
 Принята к опубликованию (Accepted): 12.07.2025