EDN VVXKMJ DOI 10.5281/zenodo.14514830
УДК 004

ДЕТЕКТИРОВАНИЕ ТРЕНДОВ МОДНОЙ ОДЕЖДЫ С ОБУЧЕНИЕМ НЕЙРОСЕТИ

© 2024 ***Евдачёва Е.Д., Максименко И.И.***

Прогнозирование модных тенденций является важнейшей задачей как для научных кругов, так и для промышленности. Ранее для решения этой сложной задачи, изучали лишь ограниченные элементы моды с сезонными или простыми узорами, которые вряд ли могли выявить реальные тенденции моды. Стремясь к прогнозированию, эта статья предназначена для исследования четких тенденций в мире моды для определенных групп пользователей. В работу был взят крупномасштабный набор данных о модных тенденциях (FIT). Так же для более эффективного моделирования временных рядов данных была взята модель рекуррентной сети, которая использует преимущество от нейронных сетей при моделировании временных рядом. Обширные эксперименты демонстрируют, что предложенная модель KERNA может эффективно улавливать сложные закономерности объективных элементов моды, следовательно, делая предпочтительный прогноз модных тенденций.

Ключевые слова: прогнозирование модных тенденций, анализ моды, прогнозирование временных рядов.

Введение. Карл Лагерфельд утверждал, что мода заключается в умении меняться. Поэтому для специалистов, которые хотят следовать этим изменениям, важно прогнозировать модные тенденции. Это помогает модным компаниям создавать продукты, быть в списках лидеров и разрабатывать маркетинговые стратегии более эффективно. Италия помогает потребителям моды делать лучший выбор. Специалисты по прогнозированию тенденций путешествуют по миру, чтобы изучить различные культурные факторы, влияющие на моду. Они обращают внимание на музыку, искусство, образ жизни и поведение потребителей. Собранная информация помогает им предсказать будущие тренды.

Прогнозирование модных тенденций основано на субъективных выводах специалистов, не несет высокую точность таких прогнозов. В последнее десятилетие из-за быстрого развития моды прогнозировать тенденции стало ещё сложнее. С другой стороны, настал век цифровых технологий. Современные технологии позволили собрать огромное количество данных о моде. Эти данные можно использовать для прогнозирования модных тенденций на основе объективного анализа.

Цель этой статьи — изучить большие объёмы исторических данных о моде и предсказать её возможное развитие в будущем.

Использование нейронных сетей для детектирования трендов модной одежды представляется обоснованным выбором по нескольким причинам. Нейронные сети способны обрабатывать большие объёмы данных, включая изображения, видео и текстовые данные. Это позволяет им выявлять закономерности и тенденции в модных трендах. Нейросети могут автоматически анализировать данные о модных тенденциях, что упрощает и ускоряет процесс анализа. Это особенно полезно для компаний, занимающихся модой, которые хотят быстро реагировать на изменения в индустрии. Так же нейронные сети могут предоставлять более точные и объективные результаты, чем человеческий анализ. Они не подвержены влиянию личных предпочтений или предубеждений.

Однако стоит отметить, что использование нейронных сетей требует значительных ресурсов и времени на обучение и настройку. Также необходимо учитывать этические аспекты использования таких технологий в сфере моды.

Анализ существующих решений. Существует несколько известных решений, которые используют глубокое обучение нейросети для прогнозирования и детектирования трендов в модной одежде. В данном разделе мы рассмотрим наиболее известные из них, а также проанализируем их преимущества и недостатки [1].

1. DeepFashion

Решение для прогнозирования модных трендов, которое использует сверхточную нейронную сеть для анализа изображений из Интернета, собранное Лабораторией Мультимедиа Китайского университета. Оно было обучено на большом количестве изображений одежды и аксессуаров и может предсказывать модные тренды на основе этих данных. DeepFashion содержит 800 тыс. изображений, которые помечены 50 категориями, 1000 атрибутами, ориентирами одежды и более 300 тыс. пар изображений. Это самый большой и полный набор данных по одежде на сегодняшний день [2].

Плюсы:

- Автоматизация процесса анализа и генерации модных образов.
- Возможность создания новых, уникальных образов на основе существующих.
- Улучшение качества и разнообразия ассортимента для ритейлеров.

Минусы:

- Необходимость большого количества данных для обучения модели.
- Риск неточных результатов в работе модели.
- Зависимость от качества и актуальности исходных данных.

2. Fashion-Gen

Решение представляет собой генеративно-состязательную сеть (GAN), которая может генерировать новые модные образы на основе существующих данных. Сеть обучается на большом наборе фотографий одежды и аксессуаров, а затем использует полученные знания для создания новых образов [3] Каждая модная вещь сопровождается описательными подписями длиной в абзац, полученными от экспертов (профессиональных дизайнеров). Распределение длины описаний представлено на рисунке 1.

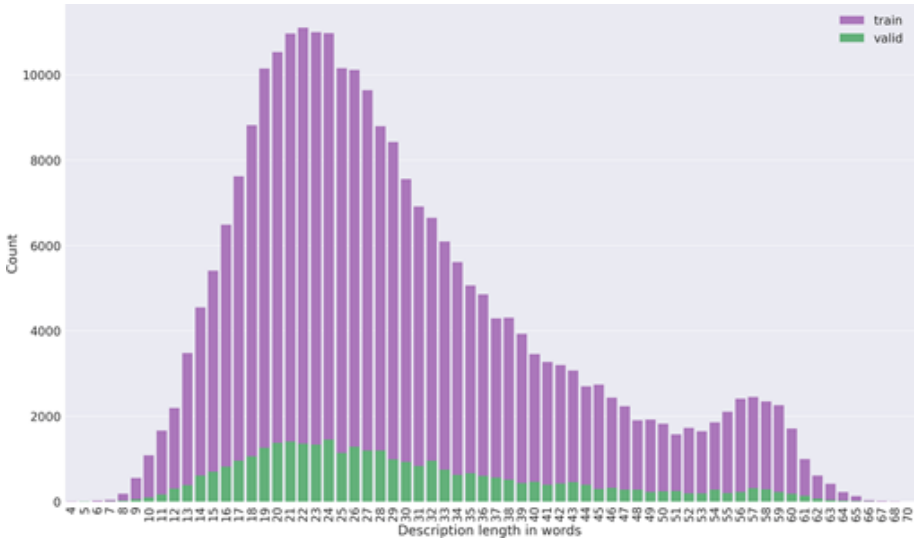

Рис. 1. График распределения длины описаний

Плюсы:

- Возможность создавать уникальные и интересные образы.
- Помощь в создании виртуальных примерочных.
- Экономия времени и денег на создание коллекций.

Минусы:

- Необходимость обучения модели на больших объемах данных.
- Риск генерации некачественных или нереалистичных изображений.

Как эффективно моделировать соответствующие данные для получения точных прогнозов? Прежде всего, исходные данные должны быть подробными и масштабными, чтобы охватывать достаточно длительный период времени и отражать изменения в моде с течением времени. По сравнению с началом модных показов, социальные сети являются более актуальным источником данных, поскольку они оперативно отслеживают тенденции моды, ежедневно публикуя фотографии и комментарии о моде из множества источников: от пользователей, модных блогеров и брендов. С помощью компьютерного зрения или других методов машинного обучения можно получить много информации о пользователях и элементах моды из изображений, метаданных и других источников. Однако наборы данных, основанные на социальных сетях, содержат ограниченное количество информации о моде и не подходят для прогнозирования значимых тенденций в индустрии моды.

В этой статье мы используем набор данных, который содержит множество подробных элементов моды, включая категорию, атрибут и стиль. Он также охватывает более длительный период времени и содержит больше информации о пользователях. Для точного прогнозирования модных тенденций необходимо эффективно фиксировать данные, на основе которых можно выявить закономерности во временных рядах. Традиционные модели, такие как статистические или матричная факторизация, хорошо работают с простыми данными временных рядов, но не позволяют делать обоснованные прогнозы для сложных тенденций моды.

Недавние достижения в области глубокого обучения позволили найти эффективные решения для многих задач. Однако этот подход ещё не применялся для анализа модных тенденций. Большинство существующих работ прогнозируют тренд для каждого элемента моды отдельно. Однако элементы моды не являются независимыми, а тесно связаны друг с другом. Например, свитер похож на модель с горловиной «черепаха», но отличается от платья. Чтобы сделать более точный прогноз тренда свитера, можно использовать результаты прогноза для «черепашьей» горловины и платья. Это позволит уточнить прогноз для свитера на основе наблюдаемых корреляций между этими элементами [4].

В мире моды существуют таксономические отношения между элементами, например, между одеждой и всеми атрибутами принадлежности (рисунок 2). Эти таксономические соотношения необходимо учитывать при моделировании модных тенденций. В этой статье используется подход под названием Knowledge Enhanced Recurrentnetwork (KERN) для прогнозирования модных тенденций среди разных групп людей. Этот подход позволяет эффективно моделировать элементы данных временных рядов, используя сложные шаблоны с помощью фреймворка кодирования-декодирования долгосрочной и краткосрочной памяти (LSTM).

Более того, KERN объединяет два типа знаний: внутренние и внешние. Внутренние знания он получает через анализ сходства временных рядов в наборе данных и вводит тройную регуляризацию потерь на основе шаблонов. Внешние знания позволяют связать элементы моды с таксономией, а также обновлять их с помощью обмена сообщениями между корпорациями.

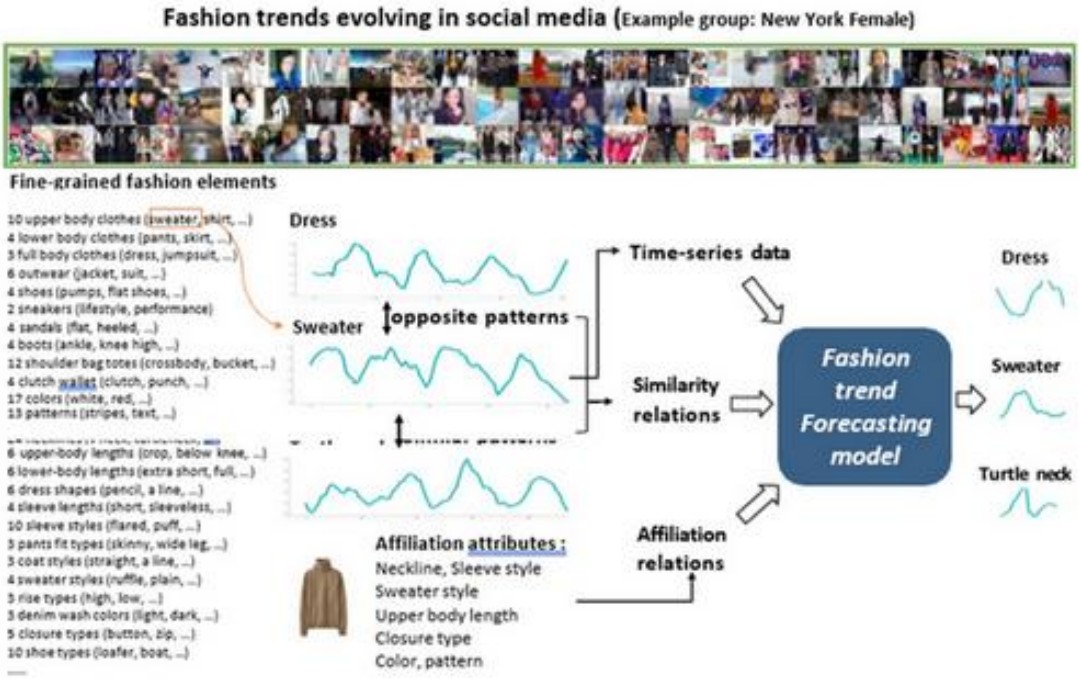

Рис. 2. Задача прогнозирования модных тенденций

Модель KERN включает в себя данные о временных рядах отдельного элемента моды и его связи с другими элементами. Мы используем информацию о пользователях, чтобы лучше моделировать модные тенденции для разных групп пользователей.

Результаты можно разделить на три группы:

1. Для определения актуальных модных тенденций мы используем большой набор данных о тенденциях в моде, основанный на данных из Instagram (Fashion Instagram Trending, или FIT).

2. Для прогнозирования модных тенденций предлагается использовать усовершенствованную модель на основе STM (KERN), которая эффективно моделирует временные ряды данных о модных тенденциях.

3. Мы показываем, что наша модель может собирать данные о модных тенденциях во временных сериях и эффективно прогнозировать их развитие.

Анализ модных тенденций. В последнее время исследователи проявляют интерес к различным задачам в области моды, таким как распознавание, поиск, смешивание, визуализация и т. д. Однако анализ модных тенденций и прогнозирование их развития всегда оставались важными классическими исследованиями в сфере моды. Они играют ключевую роль в управлении всей модной индустрией. Хидаяти и другие учёные разработали фреймворк для автоматического определения модных тенденций, которые часто встречаются на неделях моды. Виттая Корнет и другие исследователи расширили эту задачу, увеличив набор данных и изучив современную мировую моду. Их цель — провести количественный анализ моды и тенденций, а не делать прогнозы.

Matzen исследовали тенденции в одежде с помощью статистического анализа, используя масштабный набор данных об изображениях из социальных сетей.

В свою очередь, Mall сосредоточились на специфических элементах моды и попытались выявить детализированные модные тенденции. Они моделировали сигналы модных тенденций для каждого элемента с помощью комбинации линейных и циклических компонентов.

Эти компоненты, согласно исследованию, способны улавливать как общие уровни тенденций, так и тонкие изменения. Однако их исследование ограничено тем, что они рассматривали только определённые элементы моды, которые демонстрировали простые шаблоны в своих трендовых сигналах (например, наличие или отсутствие шляпы), и не включали элементы с более сложной структурой. Таким образом, существующие исследования по-прежнему ограничены статистическим анализом или прогнозированием тенденций развития определённых элементов моды на основе простых шаблонов [5].

Подход. Цель данной статьи — разработать модель для прогнозирования модных тенденций на основе исторических данных.

Мы предлагаем использовать базовую платформу LSTM encoder decoder framework, которая объединяет временные ряды и связанную с ними информацию о последовательности в единую модель и позволяет создавать многогоризонтный прогноз. Чтобы улучшить модель, мы добавляем расширенный термин «регуляризация», который явно включает внутренние знания [6]. Также мы вводим модуль передачи сообщений, чтобы использовать внешние знания, полученные из таксономии.

Предложенную систему фреймворков мы называем улучшенной рекуррентной сетью (KERN), как показано на рисунке 3

Рис. 3. Два примера из набора данных FIT, где красные кривые взяты из набора данных FIT, а синие кривые взяты из Google Trends (оба примера относятся к группе [Нью-Йорк, женщины])

Эксперимент. Чтобы проверить эффективность предложенного нами подхода, были проведены эксперименты с двумя наборами данных. В частности, нас интересуют главный вопрос для исследования:

1) Соответствует ли наша модель современным методам прогнозирования будущего модного тренда?

Экспериментальные настройки. Мы используем два набора данных для прогнозирования модных тенденций: предложенный нами набор данных о соответствии и набор данных о геостиле. Например, мы используем данные за один год (52 точки данных), чтобы предсказать результаты следующего полугодия (26 точек данных). Мы разрабатываем две настройки, которые позволяют:

1)использовать данные за два года (48 точек данных) в качестве входных данных и прогнозировать результат следующего полугодия (12 точек данных);

2)использовать данные за два года (48 точек данных) в качестве входных данных и прогнозировать результат следующего полугодия (24 точки данных).

Поскольку набор данных Geostyle содержит только один атрибут (city) и не содержит пользовательских атрибутов fage и gender, то упрощаем объединение групповых атрибутов и напрямую используем привязку к городу в качестве привязки к группе. Стратегия скользящих окон была применена к обоим наборам данных для создания обучающей и тестовой выборок.

Детали реализации. Мы устанавливаем размер привязки к пользователям (включая привязку к возрасту, полу и городу), размер привязки к элементам одежды и времени до 10, а также размер каждого кода и декодера в нашей сети to50. Гиперпараметр λ для регуляции равен 2×10-4. Во время обучения случайным образом отбираем набор из 400 различных временных рядов для каждой итерации. Для каждой экспериментальной установки настраиваем одну модель ядра для всех модных элементов. Для каждого тестового примера вычисляем эффективность текущих точек данных в соответствии с результатами проверки, а также эффективность последующих точек данных в соответствии с результатами тестирования.

Базовые методы. Выбираем несколько современных методов прогнозирования временных рядов для сравнения с предложенной базовой моделью: среднее и последнее. В качестве прогнозного значения используется среднее значение или значение последней точки в исходных исторических данных.

Авторегрессия(AR) - линейный регрессор, который использует линейную комбинацию последних наблюдаемых значений с предшествующим значением.

Векторная авторегрессия (VAR) - обобщение ARby, допускающее более одной изменяющейся переменной.

Экспоненциальное сглаживание (ES) - объединяет все исторические значения с показательно уменьшенным весом, более поздние значения оказывают большее влияние на прогноз будущего [7].

Линейная и циклическая - линейная или циклическая параметрическая модель, историческое значение которой соответствует конкретной заданной модели.

Геостиль - параметрическая модель, сочетающая линейный компонент и циклический компонент. Это современный метод прогнозирования модных тенденций в наборе геостилированных данных

Мы оцениваем эффективность нашей модели для прогнозирования модных тенденций, сравнивая её с несколькими классическими и современными базовыми моделями. Результаты представлены в таблице 1.

На основе полученных данных мы можем сделать следующие выводы:

1. Модель KERN показывает наилучшие результаты на обоих наборах данных при любых экспериментальных настройках. В частности, на Geostyle только KERN позволяет получить MAE ниже 0,014 и MAPE ниже 15%.

2. На Offitdataset все базовые модели показали MAE и MAPE около 0,11 и 40% соответственно. Наша модель достигает значений менее 0,1, а MAPE — около 30%, что говорит о её высокой производительности.

Набор данных Fitdataset содержит больше детализированных элементов моды, информации для пользователей и более реалистичные и сложные шаблоны временных рядов. Поэтому его сложнее моделировать.

Таблица 1. Показатели KERN и базовые показатели для прогнозирования модных тенденций

Полгода			Полгода		Один год	
Метод	MAE	MAPE	MAE	MAPE	MAE	MAPE
Mean	0.0292	25.79	0.132	65.31	0.135	63.21
Last	0.0226	21.04	0.125	46.45	0.147	54.04
AR	0.0211	20.69	0.114	54.36	0.119	51.96
VAR	0.0150	17.95	0.157	62.97	0.126	47.35
ES	0.0228	20.59	0.133	55.29	0.150	57.42
Linear	0.0365	24.40	0.112	43.30	0.133	45.89
Cyclic	0.0165	16.64	0.129	49.92	0.143	51.66
GeoStyle	0.0149	16.03	0.136	52.40	0.149	53.14
KERN	**0.0134**	**14.24**	**0.083**	**30.02**	**0.094**	**33.45**

Базовые методы не могут эффективно работать с таким набором данных. Однако наш основной метод справляется со сложными шаблонами лучше других базовых моделей. Это связано с тем, что он обеспечивает лучшую нелинейность в данных, а также позволяет использовать обширные знания о домене. Именно поэтому наша модель показывает улучшение стиля.

Большинство методов дают лучшие результаты при полугодовом прогнозе, чем при годовом, включая нашу основную модель.

Обсуждение эффективности внедрения знаний (RQ2). В этой работе проводим эксперименты и анализируем, насколько эффективно можно внедрить корпоративные знания в модель прогнозирования модных тенденций.

Используем два типа знаний:

1. внутреннее знание отношений подобия, которое применяется путём введения члена триплетной регуляризации в функцию потерь;

2. внешнее знание отношений принадлежности, построенное на основе таксономии, которое используется путём обновления встроенных элементов fashion через передачу сообщений в соответствии с деревом принадлежности.

Чтобы оценить эффективность каждого типа знаний, мы тестируем модель, удаляя каждый тип по очереди, а также оба одновременно. Модель без использования внутренних знаний (KERN-I) игнорирует потерю триплетной регуляризации, а модель без использования внешних знаний (KERN-E) не оснащена модулем включения внешних знаний.

Модель KERN-IE не содержит ни внутренних, ни внешних знаний. Из показателей в таблице 2 видно, что удаление отношений принадлежности или сходства может ухудшить производительность нашей модели. Разница, получаемая за счёт использования дополнительных знаний, более существенна для долгосрочного прогнозирования на основе подходящего набора данных. Это показывает, что использование знаний может быть особенно полезным для получения сложных и требующих проверки данных.

Таблица 2. Вклад различных знаний в модель KERNA (результаты MAE)

Датасет	GeoStyle	FIT	
Предсказание	Полгода	Полгода	Один год
KERN-IE	0.0137	0.0840	0.0966
KERN-E	-	0.0835	0.0953
KERN-I	0.0134	0.0831	0.0942
KERN	0.0134	0.0836	0.0939

На рисунке 4 показаны два примера, в которых сравниваются результаты прогнозирования тенденций с помощью KERN и удалённого KERN-IE. Результаты прогнозирования с помощью KERN явно лучше, чем с помощью KERN-IE, что ещё раз показывает преимущества использования внутренних и внешних знаний в модели KERN [8].

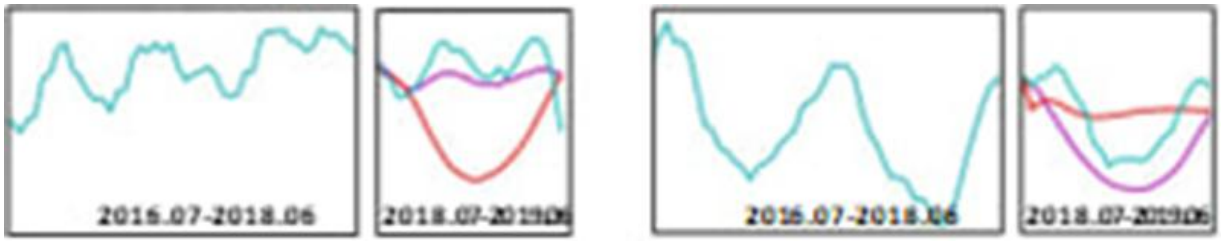

Рис. 4. Два примера прогнозирования тенденций, выполненных с помощью моделей KERN и KERN-IE:
Основная истина Прогнозирование с использованием пользовательской информации
Прогнозирование без информации о пользователе

Анализ модных тенденций (RQ3). Чтобы ещё раз проиллюстрировать эффективность нашей модели KERN для прогнозирования моды, мы представляем дополнительные результаты визуализации.

На рисунке 5 показан прогноз на год и полугодие для шести репрезентативных элементов моды (включая категорию одежды, обуви, цвет, рисунок и атрибуты) для трёх групп пользователей. Мы видим, что в целом KERN может очень хорошо прогнозировать тенденции в модных элементах как на год, так и на полгода, даже для тех, у кого довольно сложные модели.

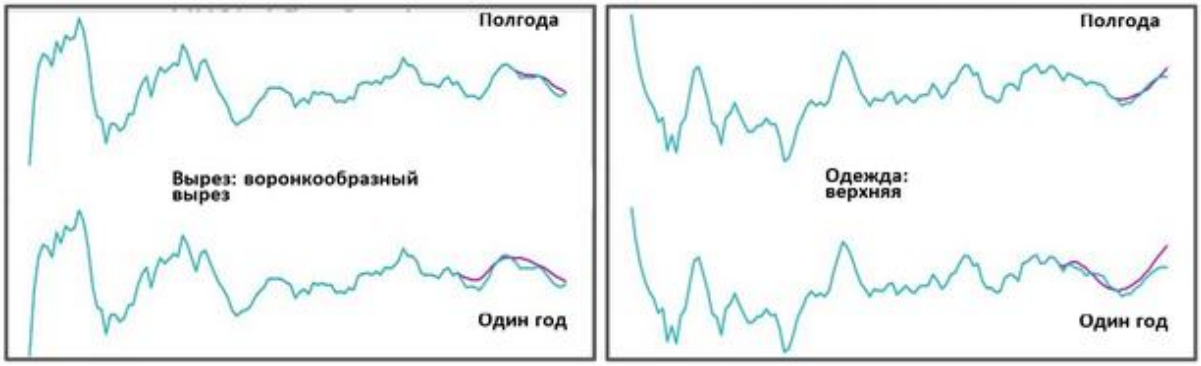

а) Лос-Анджелес, женщина, 18-25 лет

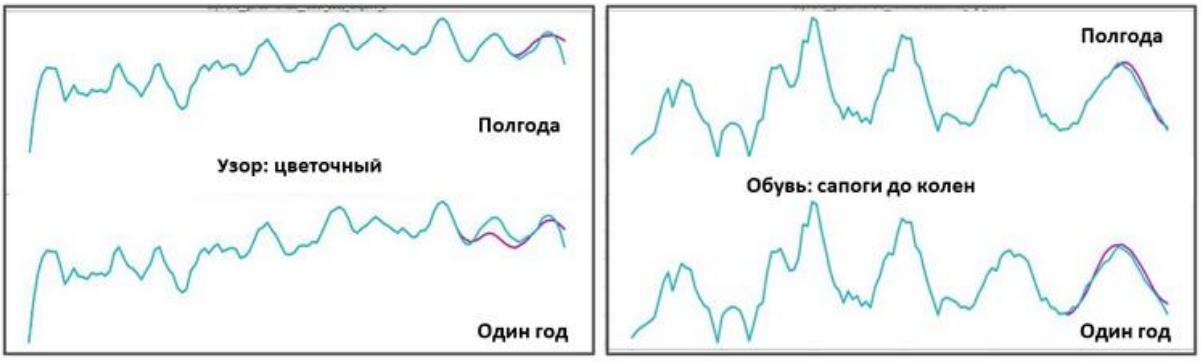

б) Париж, женщина

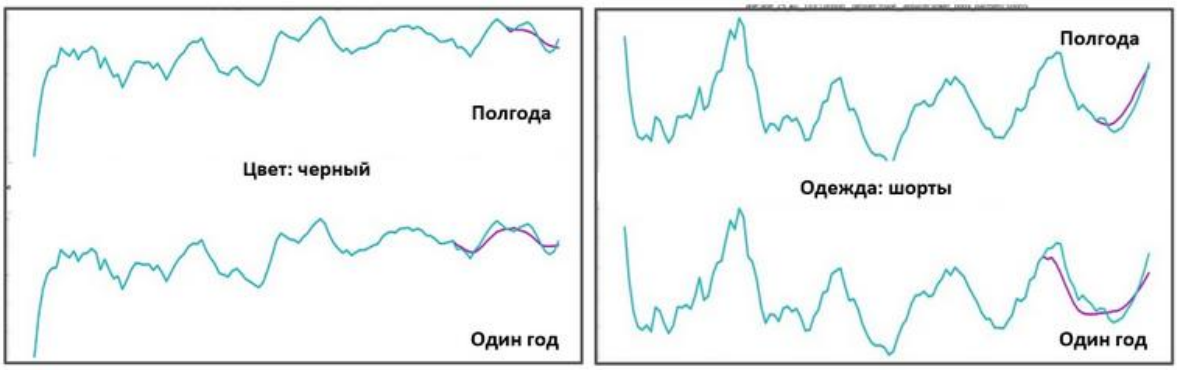

в) Лондон, мужчина, 25-40 лет

Рис. 5. Примеры прогнозирования тенденций для различных элементов моды и групп пользователей: Голубые кривые соответствуют действительности, а фиолетовые - результатам прогнозирования KERNA

Результаты на рисунке 6 показывают, что один и тот же элемент моды для разных групп пользователей может отличаться. Это также демонстрирует, что метод KERN способен эффективно предсказывать различные тенденции, используя информацию о пользователях. Результаты прогнозирования с использованием информации о пользователях намного лучше, чем без неё.

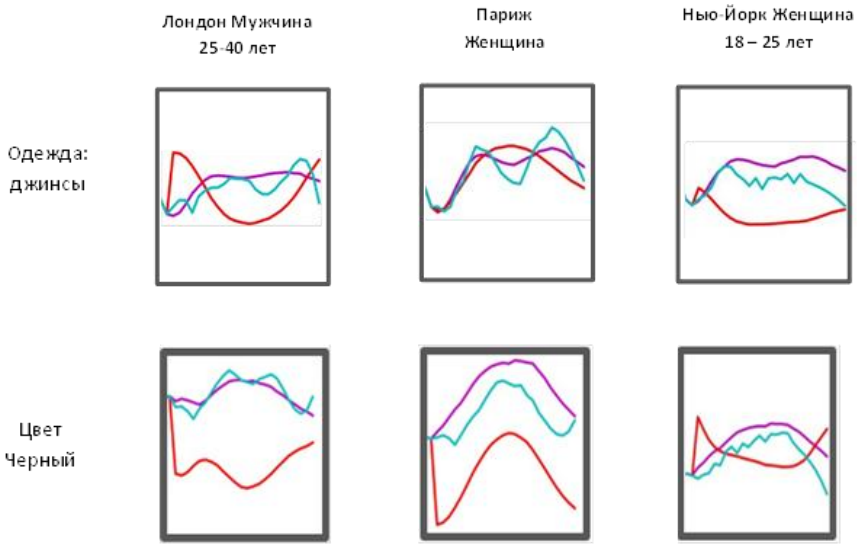

Рис. 6. Результаты прогнозирования одного модного элемента для разных групп пользователей:
Основная истина Прогнозирование с использованием пользовательской информации
Прогнозирование без информации о пользователе

На основе прогнозирования различных типов модных элементов мы можем составить подробный и профессиональный отчёт о тенденциях моды. Он охватывает множество модных тенденций, включая категорию, цвет, рисунок, стиль и даже такие подробные характеристики, как цвет.

Заключение. В этой статье рассматривается проблема прогнозирования модных тенденций на основе данных из социальных сетей. Цель исследования — выявить сложные закономерности в исторических записях временных рядов элементов моды и спрогнозировать будущие тенденции.

Для этого была протестирована эффективная модель Knowledge Enhanced Recurrent Network (KERN), которая позволяет фиксировать сложные закономерности во временных рядах данных и прогнозировать модные тенденции.

Хотя были приложены значительные усилия и получены желаемые результаты, есть некоторые аспекты, которые можно улучшить в будущем. Во-первых, необходимо изучить больше информации о пользователях, например, об их профессиях или хобби. Во-вторых, следует учитывать многочисленные источники знаний, такие как анализ моды из профессиональных модных журналов, блогов и брендов.

СПИСОК ИСТОЧНИКОВ

1. Zhu, S. A Be Your Own Prada: Fashion Synthesis with Structural Coherence / S. Zhu. – 2017. – URL: https://arxiv.org/abs/1710.07346.
2. Large-scale Fashion (DeepFashion) Database [Электронный ресурс]. – URL: https://mmlab.ie.cuhk.edu.hk/projects/DeepFashion.html (дата обращения 10.09.2024).
3. Fashion-Gen: The Generative Fashion Dataset and Challenge [Электронный ресурс]. – URL: https://deepai.org/publication/fashion-gen-the-generative-fashion-dataset-and-challenge (дата обращения 10.09.2024).
4. Власенко, А. И. Анализ методологии прогнозирования модных трендов / А. И. Власенко. – СПб: Издательство СПбГУ, 2020. – 120 с.
5. Использование нейросетей в индустрии моды [Электронный ресурс]. – URL: https://www.researchgate.net/publication/376596939_Ispolzovanie_nejrosetej_v_industrii_mody (дата обращения 12.09.2024).
6. Details of the LSTM [Электронный ресурс]. – URL: https://www.researchgate.net/figure/Details-of-the-LSTM-and-Bi-LSTM-models_fig5 (дата обращения 12.09.2024).
7. Построение моделей временных рядов [Электронный ресурс]. – URL: https://www.iprbookshop.ru/68826.html (дата обращения 12.09.2024).
8. Предсказание временных рядов с помощью нейросети Keras [Электронный ресурс]. – URL: https://newtechaudit.ru/predskazanie-vremennyh-ryadov-s-pomoshhyu-keras/ (дата обращения 12.09.2024).

Поступила в редакцию 28.10.2024 г., рекомендована к печати 14.11.2024 г.

DETECTING FASHION TRENDS WITH NEURAL NETWORK TRAINING

Evdacheva E.D., Maksimenko I.I.

Forecasting fashion trends is a crucial task for both academia and industry. Previously, to solve this difficult task, only limited fashion elements with seasonal or simple patterns were studied, which could hardly reveal real fashion trends. Aiming at forecasting, this article is intended to explore clear trends in the fashion world for certain user groups. A large-scale data set on fashion trends (FIT) was used in the work. Also, for more efficient modeling of time series of data, a recurrent network model was taken, which takes advantage of neural networks when modeling time series. Extensive experiments demonstrate that the proposed CORE model can effectively capture complex patterns of objective fashion elements, therefore making a preferable forecast of fashion trends.

Keywords: forecasting fashion trends, fashion analysis, forecasting time series.

Евдачёва Екатерина Дмитриевна
магистрант кафедры компьютерных технологий ФГБОУ ВО «Донецкий государственный университет»,
Российская Федерация, ДНР, г. Донецк.
E-mail: alisakovallllll@gmail.com

Evdacheva Ekaterina Dmitrievna
Master Student at Department of Computer Technologies of Donetsk State University,
Russian Federation, DPR, Donetsk.

Максименко Игорь Иванович
кандидат физико-математических наук, доцент кафедры компьютерных технологий ФГБОУ ВО «Донецкий государственный университет»,
Российская Федерация, ДНР, г. Донецк.
E-mail: igor.maksimenko_1967@mail.ru

Maksimenko Igor Ivanovich
Candidate of Physical and Mathematical Sciences, Associate professor at Department of Computer Technologies of Donetsk State University,
Russian Federation, DPR, Donetsk.