

СМЕЩЕНИЯ В МУЗЫКАЛЬНЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМАХ: ОБЗОР, ФОРМАЛИЗАЦИЯ, КЛАССИФИКАЦИЯ И МЕТОДЫ ДЕБАЙСИНГА

Сеняткин Никита Станиславович

аспирант, Российская Академия Народного Хозяйства
и Государственной Службы при Президенте РФ, г. Москва
719042427@telegram.wappi

BIASES IN MUSICAL RECOMMENDER SYSTEMS: SURVEY, FORMALIZATION, CLASSIFICATION AND DEBIASING METHODS

N. Seniatkin

Summary. The paper provides a structured systematization of biases inherent to recommender systems with aim to musical domain. The survey introduces an integrated taxonomy that captures both general algorithmic distortions and domain-specific effects characteristic of the music industry. The study formulates the core objective of consolidating fragmented knowledge about data-driven, algorithmic, and socio-contextual biases into a unified analytical framework. It identifies key distortions observed in practice, including popularity, exposure, and position biases, as well as genre, cultural, gender, and label-related inequalities amplified by feedback loops and repetitive content consumption behavior. The work formalizes these phenomena using quantitative measures such as popularity and diversity indicators, exposure and fairness-oriented metrics, and bias amplification coefficients. It further classifies mitigation strategies applied at the stages of data preprocessing, model training, and post-ranking adjustment, emphasizing the need for domain adaptation due to the strong impact of playlists, seasonal trends, and structural asymmetries between artists. The results establish a methodological foundation for evaluating fairness in music recommendation and outline research prospects, including the development of domain-specific metrics, datasets enrichment, and frameworks that find fairness balance between users and artists interests.

Keyword: recommender systems, music streaming, music recommender systems, machine learning, data bias, bias evaluation, genre bias, specific bias, debiasing.

Аннотация. Статья посвящена систематизации смещений, возникающих в рекомендательных системах, особый упор сделан на домен музыкальных рекомендательных систем. В работе предлагается единая таксономия, учитывающая как общие для рекомендательных алгоритмов искажения, так и доменные особенности музыкальной индустрии. Сформулирована исследовательская задача — объединить разрозненные знания о смещениях в данных, алгоритмах и социальном контексте в структурированную модель. В работе представлены ключевые типы искажений, включая популярность, экспозиционные и позиционные смещения, а также жанровые, культурные, гендерные и лейбловые перекосы, усиленные эффектами обратной связи и характером повторного потребления. Описаны и структурированы метрики, позволяющие формализовать эти явления: показатели популярности и разнообразия, метрики экспозиции, справедливости и усиления смещений. Систематизированы методы смягчения смещений на этапах подготовки данных, обучения моделей и переранжирования выдачи. Показано, что в музыкальном домене классические подходы требуют адаптации из-за высокой повторяемости потребления, влияния плейлистов и асимметрии между артистами. Полученные результаты формируют основу для разработки справедливых музыкальных рекомендаций и определяют направления дальнейших исследований, связанных с метриками, датасетами и учетом интересов разных сторон экосистемы.

Ключевые слова: рекомендательные системы, обзор, музыкальные сервисы, музыкальные рекомендательные системы, смещения данных, машинное обучение, специфические смещения, дебайсинг.

Введение

Развитие музыкальных стриминговых платформ радикально изменило способы потребления музыки. Сервисы вроде *Spotify*, *Apple Music* «VK Музыка» и «Яндекс Музыка» формируют значительную часть музыкального трафика, а персонализированные рекомендательные системы (РС) стали главным инструментом навигации по контенту [1]. Такие системы упрощают пользователям поиск музыки, но одновременно оказывают влияние на их вкусы, определяя, какие исполнители и жанры получают наибольшую видимость и внимание [2; 3].

Опыт исследователей и промышленных инженеров за последние годы показал, что рекомендательные системы подвержены множественным смещениям (*bias*), возникающим не только на технических этапах рекомендаций, таких как сбор данных, кандидатогенерация, ранжирование, но и на административных этапах (взаимодействие с лейблами). Наиболее часто встречающиеся в исследованиях смещения включают в себя смещение популярности (*Popularity bias*), экспозиции (*Exposure bias*), позиции (*Positional bias*), а также эффекты обратной связи (*Feedback loop*) и социального влияния (*Social bias*) [4–7]. Игнорирование данных смещений влечет за собой риски того, что рекомендательные системы будут наибо-

лее часто рекомендовать популярные объекты, а также ограничивать разнообразие рекомендаций, заворачивая вкусы пользователей «в пузырь», снижая шансы менее известных, но потенциально релевантных рекомендаций, попасть в рекомендации широкой аудитории [8].

Каждая доменная область рекомендательных систем имеет свои уникальные особенности, музыкальные рекомендации не исключение. Музыка характеризуется высокой степенью повторного потребления, сильным влиянием редакторских и пользовательских плейлистов, ярко выраженной сезонностью и жанрово-культурными различиями. В результате здесь проявляются специфические виды смещений: смещение при попадании в плейлист — смещение рекомендательной системы, характеризующееся многократным увеличением вероятности рекомендации треков, которые попали в крупный плейлист [9]; жанровое и культурное смещение, выражающееся в недопредставленности нишевых жанров, особо характерных определенной культуре [1]; смещение по автору/метаданным — смещение, при котором пол артиста, его популярность, лейбл определяют его представленность среди рекомендованных треков [3;10]; временное смещение, отражающее зависимость от краткосрочных трендов и сезонных хитов [2].

В процессе изучения представленных научных работ было замечено, что в исследовательском поле нет трудов, посвященных систематизации знаний в области смещений музыкальных рекомендательных систем, было решено собрать и обобщить накопленные труды в области смещений, учитывая специфику музыкальной области. Настоящая статья ставит целями:

1. провести обзор известных смещений в рекомендательных системах и методов их анализа;
2. выделить и классифицировать уникальные смещения, характерные для музыкальных сервисов;
3. предложить таксономию смещений, объединяющую общие и специфические для музыки проявления.

Актуальность работы заключается в создании уникальной для музыкальных рекомендательных систем таксономии смещений, объединяющей общие и специфические для музыкального контекста смещения. В отличие от существующих подходов, где упор делается в основном на популярность или экспозицию, мы выделили:

- жанровые и стилистические перекосы;
- гендерный дисбаланс среди исполнителей;
- лейбловую асимметрию (доминирование крупных компаний);
- региональные и культурные различия.

Основной вклад исследования заключается в систематизации накопленных знаний о смещениях в музыкальной индустрии, введении уникальной классифи-

кации смещений, ориентированной на музыкальные рекомендательные системы. Данный обзор представляет агрегированные знания касательно основных смещений в музыкальных рекомендательных системах, облегчая работу для исследователей и практиков в области решения задач оценки справедливости рекомендаций, а также в области разработки методов дебайсинга, учитывающих специфику музыкальной индустрии. Исследование открывает возможность систематического анализа именно музыкальных РС, что ранее было предметом лишь отдельных исследований.

Смещения в рекомендательных системах

Общие смещения в рекомендательных системах

Проблема смещений в рекомендательных системах стала активно изучаться в последние годы, что отражено в ряде обзорных работ [6; 8]. Под смещением понимаются систематические искажения в данных или в алгоритмах, которые приводят к несправедливому или неравномерному распределению рекомендаций.

Наиболее изученным является смещение популярности (*popularity bias*) — тенденция рекомендательных алгоритмов усиливать видимость уже популярных объектов [8; 11]. Оно связано с так называемым эффектом Матфея («богатые становятся богаче»), когда известные элементы продолжают накапливать внимание пользователей [5].

Экспозиционное смещение (*exposure bias*) отражает тот факт, что пользователи могут не взаимодействовать с объектами просто потому, что они не были показаны в выдаче [6]. Близкое явление — позиционное смещение (*position bias*), когда вероятность выбора элемента зависит от его позиции в списке.

Особое внимание уделяется смещению отбора (*selection bias*): поведенческие данные отражают лишь выбор подмножеств контента, что приводит к искажению модели предпочтений [4].

Ключевую роль играет петля обратной связи (*feedback loop bias*): модель обучается в том числе на данных, которые были ею предложены, усиливая уже существующие тенденции [5]. Это ведет к гомогенизации пользовательского опыта и снижению разнообразия.

Также активно исследуется смещение социального влияния (*social influence bias*) — склонность пользователей корректировать оценки и выборы в зависимости от оценок других [7].

Таким образом, современные работы выделяют широкий спектр смещений: популярности, экспозиции,

позиции, отбора, социального влияния, а также их комбинации. Изобретено множество различных методов дебайсинга, включая перебалансировку данных, каузальные модели и переранжирование [6].

Смещения, специфичные для музыкальных рекомендательных систем

В музыкальной индустрии смещения приобретают дополнительные черты, связанные с особенностями потребления и производства контента. Ряд исследований обращает внимание на то, что музыка отличается высокой кратностью прослушиваний, влиянием плейлистов и доминированием крупных лейблов и артистов [1; 9; 10].

Смещение плейлистов (*playlist bias*). Попадание трека в популярный плейлист значительно увеличивает вероятность его дальнейшего продвижения системой [9]. Поэтому одним из действующих и эффективных способов продвижения трека в рекомендательной системе является его попадание в крупные плейлисты.

Жанрово-культурное смещение (*genre & cultural bias*). Исследования фиксируют недопредставленность нишевых и этнических жанров в рекомендациях [1]. Особенно сильно это выражается на небольших жанрах, характерных для небольших этнических групп. Это приводит к культурному неравенству, размытию границ между культурами, а также к снижению разнообразия музыкального опыта. Международные сервисы наиболее сильно подвержены данному типу смещений.

Смещение по артистам и метаданным (*artist/metadata bias*). Работа *Shakespeare D.* и соавт. [3] показывают значительный гендерный перекоп: алгоритмы чаще рекомендуют треки артистов мужского пола. Помимо гендерного перекопа, на прослушиваемость трека влияет отношение автора к лейблу. Исследование *Knees* и соавт. [10] показывает, что крупные лейблы играют важнейшую роль в представленности артиста в музыкальном сервисе.

Временные смещения (*temporal bias*). Музыкальные тренды характеризуются сезонными пиками (например, новогодние песни), которые алгоритмы усиливают, снижая представленность стабильного контента [2]. Существует риск попадания сезонного популярного контента в рекомендации нишевых пользователей, что может способствовать их оттоку из сервиса.

Помимо уникальных смещений, ряд общих смещений имеет чрезмерное влияние на музыкальные РС. Петля обратной связи. Концепция традиционных рекомендательных систем редко подразумевает рекомендации объектов, с которыми пользователь уже взаимодействовал, однако концепция потребления музыкального контента основана на частых повторных прослушивани-

ях понравившихся треков, поэтому рекомендации уже знакомых треков в музыкальной индустрии поощряются, в связи с этим, модели сильно подвержены снижать разнообразие рекомендаций и предлагать уже устоявшиеся для пользователя треки, делая разнообразие рекомендаций крайне низким.

Петля обратной связи в музыкальных рекомендациях является предпосылкой к возникновению следующих двух смещений:

1. перепредставленность в рекомендациях (*Overexposure Bias*) — пользователю предлагаются одни и те же треки или артисты слишком часто, что приводит к усталости или раздражению.
2. «застой» в рекомендациях (*Recommendation Staleness*) — более сильная форма перепредставленности, характеризующаяся систематическими рекомендациями одного и того же. Иногда этот эффект даже имеет определенный паттерн — пользователю рекомендуется с определенной периодичностью список одних и тех же треков практически в том же порядке. В связи с этим, пользователь выучивает рекомендации, что негативно влияет на его опыте работы с системой.

Обобщая вышесказанное, музыкальные рекомендательные системы подвержены уникальным искажениям. Именно это обосновывает необходимость предложенной в работе новой классификации смещений, ориентированной на специфику музыкальной области.

Метрики оценки смещений

Измерение смещений в рекомендательных системах требует введения статистических показателей, отражающих искажения в распределении рекомендаций. В литературе предложен широкий спектр метрик, которые можно разделить на три группы:

1. метрики популярности и разнообразия;
2. метрики экспозиции и справедливости;
3. метрики усиления смещений.

Метрики популярности и разнообразия

Для оценки того, насколько рекомендации склоняются к уже популярным объектам, применяют простые и интерпретируемые метрики.

Доля популярного контента. Показывает среднюю долю «популярных» объектов в выдаче:

$$PR = \frac{1}{|U|} \sum_{u \in U} \frac{|L_u \cap P|}{|L_u|}, \quad (1)$$

где L_u — топ- k рекомендаций для пользователя u , P — предопределенное множество популярного контента (например, верхние 1 % по просмотрам).

Разнообразие. Показывает, насколько сильно разнообразны рекомендации. Один из популярных подходов — использование эмбедингов объектов и расчет сходства между ними. Одна из таких метрик — *Intra List Similarity (ILS)* [12]. Данная метрика оценивает попарную схожесть между рекомендуемыми объектами.

$$ILS(R) = \frac{1}{|R|(|R| - 1)} \sum_{i \in R} \sum_{j \in R, j \neq i} sim(i, j) \quad (2),$$

где R — список рекомендованных элементов, $|R|$ — его длина, а $sim(i, j)$ — мера сходства между элементами i и j .

Коэффициент Джини. Широко используется для измерения концентрации (неравномерности) распределения внимания между объектами [13]. Пусть x_i — число взаимодействий для объекта $i, i = 1, \dots, n$. Тогда

$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n |x_i - x_j|}{2n \sum_{i=1}^n x_i} \quad (3)$$

Значение G находится в интервале $[0, 1]$: $G = 0$ соответствует полному равенству (все объекты имеют одинаковую долю в выдаче рекомендательной системы), а $G \rightarrow 1$ — сильной концентрации на небольшом числе объектов.

Энтропия Шеннона. Для оценки разнообразия выдачи полезно вычислять энтропию распределения появления объектов [14]:

$$H = -\sum_{i=1}^n p_i \log p_i \quad (4)$$

где p_i — эмпирическая вероятность появления объекта i в рекомендованных списках. Энтропия чувствительна к числу возможных объектов и к тому, насколько равномерно распределены их вероятности.

Покрывание длинного хвоста (Long-tail Coverage).

$$LTC = \frac{|L_{tail} \cap R|}{|L_{tail}|} \quad (5)$$

где L_{tail} — множество объектов «длинного хвоста» (объектов, имеющих небольшую популярность), R — множество всех рекомендованных объектов.

Метрики экспозиции и справедливости

Эти метрики позволяют оценить, какой объект получает внимание, и насколько распределение экспозиции согласуется с релевантностью [15].

Средняя экспозиция.

$$E(i) = \frac{1}{|U|} \sum_{u \in U} I[i \in L_u] \quad (6)$$

где $I[i \in L_u]$ — индикатор попадания объекта i в выдачу для пользователя u .

Разность экспозиции. Для сравнения двух групп объектов (позволяет оценить разницу экспозиции между двумя группами объектов) используют:

$$ED = \frac{E(G_1)}{|G_1|} - \frac{E(G_2)}{|G_2|} \quad (7)$$

где $E(G)$ — суммарная экспозиция группы G , а $|G|$ — размер группы.

Метрики оценки усиления смещений

Важнейшие метрики для анализа смещений, вызванных самим рекомендательным алгоритмом, позволяющие сравнить между собой «органические» взаимодействия пользователей и взаимодействия пользователей с рекомендуемыми объектами. Данная группа метрик направлена на выявление различного рода смещений, которые провоцируются самим рекомендательным алгоритмом.

Коэффициент усиления (Amplification Factor, AF).

$$AF = \frac{Bias_{rec}}{Bias_{data}} \quad (9)$$

где $Bias_{data}$ — выбранная метрика смещения в исходных логах (например, Gini по прослушиваниям), а $Bias_{rec}$ — та же метрика, вычисленная по рекомендованным спискам. Значение $AF > 1$ указывает на усиление смещения алгоритмом.

Усиление популярного (Popularity Lift). Разница в вероятности появления популярного объекта в рекомендациях и в данных:

$$PL = P_{rec}(i \in P) - P_{data}(i \in P) \quad (10)$$

Неравенство представленности (Bias Disparity). Разница в представленности одних и тех же объектов рекомендаций в обучающем наборе данных и в тестовом наборе данных. Bias Disparity:

$$BD = \frac{1}{|G|} \sum_{g \in G} \left| \frac{|I_g^{train}|}{|I^{train}|} - \frac{|I_g^{test}|}{|I^{test}|} \right| \quad (11)$$

где I_g — объекты группы g .

Сильный перекоп по данной метрике указывает на выраженный дисбаланс между обучающими данными и данными, на которых модель будет работать.

Приведенные метрики позволяют формализовать как общие смещения (например, популярности), так и специфические для музыкальных систем (например, различия в экспозиции артистов разных жанров или полов). Использование этих показателей обеспечивает количественную основу для анализа и последующего дебайсинга рекомендательных моделей.

Классификация смещений в музыкальных рекомендательных системах

Существующие классификации смещений в рекомендательных системах, представленные в работах [6; 8; 16], в основном охватывают общие категории — популярности, экспозиции, позиции и социального влияния. Однако специфика музыкальных платформ приводит к возникновению уникальных, контент-зависимых и контент-зависимых смещений.

Музыка имеет уникальный паттерн потребления, скорость ее потребления сильно выше, чем в других сферах, а большое количество перепрослушиваний одного и того же — ее характерная черта. Более того, смещения в музыкальных рекомендательных системах имеют более сложную структуру: они связаны не только с пользовательским поведением, но и с особенностями самой индустрии — наличием крупных лейблов, жанровой сегрегацией и временной динамикой популярности.

На основании анализа литературы [1; 3; 5; 9; 10] предлагается расширенная таксономия смещений, объединяющая общие и специфические для музыкальных систем проявления.

Предложенная классификация объединяет 10 ключевых типов смещений, сгруппированных по их источникам и механизму проявления (таб. 1). Она позволяет различать:

- смещения, зависящие от данных (*selection, popularity, exposure, playlist*);
- алгоритмические смещения (*position, feedback loop*);
- социально-контекстные смещения (*social influence, genre/cultural, artist/metadata, temporal*).

Таким образом, предложенная таксономия формализует смещения, которые возникают в рекомендательных системах, а также является фундаментом для анализа смещений в музыкальных рекомендательных системах.

Методы устранения и смягчения смещений

Методы снижения влияния смещений можно разделить на три класса в зависимости от этапа вмешательства: предобработка данных, обучение алгоритмов и переранжирование.

Таблица 1.

Классификация смещений в музыкальных рекомендательных системах

Уровень	Тип смещения	Проявление в музыкальных РС	Ключевые метрики
Данные	<i>Popularity bias</i>	Усиление доминирования популярных треков и артистов в выдаче.	<i>Gini</i> (3), <i>Popularity share</i> (1)
Данные	<i>Selection bias</i>	Поведенческие логи отражают лишь часть реальных предпочтений.	<i>Bias Disparity</i> (11), <i>IPS</i> -параметры
Данные	<i>Feedback loop bias</i>	Рекомендательный цикл усиливает уже рекомендованные объекты.	<i>Amplification Factor</i> (9), <i>Popularity Lift</i> (10), <i>time-based ED</i> (7)
Алгоритмы	<i>Exposure bias, Overexposure bias</i>	Контент получает чересчур неравномерное внимание со стороны системы.	<i>E(i)</i> (6)
Алгоритмы	<i>Position bias</i>	Верхние позиции в выдаче получают несоразмерное количество кликов.	<i>PBM</i> (12), <i>CTR@p</i>
Алгоритмы	<i>Recommendation Staleness</i>	Систематические рекомендации одного и того же.	<i>ILS by user</i> (2), <i>Time-based User's ED</i> (7)
Социальные явления	<i>Genre bias</i>	Недопредставленность нишевых и локальных жанров.	<i>Entropy</i> (4), <i>LTC</i> (5)
Социальные явления	<i>Artist gender bias</i>	Неравное распределение в выдаче между артистами разных полов.	<i>Exposure Disparity</i> (7)
Социальные явления	<i>Label bias</i>	Крупные лейблы получают преимущество в экспозиции.	<i>Exposure per label, ED</i> (7)
Социальные явления	<i>Language / Regional / Cultural bias</i>	Доминирует язык и культура крупнейшей группы слушателей.	<i>Share by language / region</i>

Предобработка направлена на коррекцию исходных данных и включает балансировку выборки, корректировку экспозиции (например, IPS-подходы), агрегацию данных для новых релизов и фильтрацию рекомендательных логов. В музыкальной индустрии на практике чаще всего применяются фильтрация данных и корректировка экспозиции с приоритетом органических взаимодействий.

На уровне **алгоритмов** используются регуляризации, штрафы за неравномерную экспозицию и мультиобъектная оптимизация, учитывающая компромисс между точностью и разнообразием. Отдельное направление связано с обучением моделей на отклонениях от средних значений например (biased — коллаборативные фильтрации), что позволяет частично снижать эффекты экспозиционного смещения и застоя.

Переранжирование применяется на финальном этапе и основано на бизнес-правилах и ограничениях на разнообразие. Наиболее распространены квотирование тех или иных категорий и жанрово-артистические ограничения, позволяющие повысить разнообразие рекомендаций при контролируемом снижении точности.

Каждый класс вышеуказанных методов имеет практические **ограничения**: предобработка требует доступа к избыточной детализации данных, содержание которой требует огромного количества памяти, обучение — модификации моделей и дополнительных вычислительных

ресурсов, а переранжирование может снижать релевантность рекомендаций. В реальных системах методы обычно комбинируются с учётом архитектурных и бизнес-ограничений.

Перспективы исследований

Анализ показывает, что существующие работы ограничены недостаточной адаптацией метрик к музыкальному домену, ограниченностью публичных датасетов и фокусом преимущественно на стороне пользователя, а не артиста. Перспективными направлениями являются разработка доменно-специфичных метрик справедливости, сбор более богатых музыкальных датасетов, исследование двусторонней справедливости и учёт мультикультурного контекста рекомендаций.

Заключение

В работе рассмотрены основные типы смещений в рекомендательных системах и предложена их классификация, объединяющая общие и музыкально-специфичные факторы. Показано, что музыкальный контекст усиливает эффекты петли обратной связи, застоя и неравномерной представленности артистов и жанров. Предложенный обзор и систематизация создают основу для разработки методов и метрик, ориентированных на справедливость и разнообразие в музыкальных рекомендациях.

ЛИТЕРАТУРА

- Hesmondhalgh D. et al. The impact of algorithmically driven recommendation systems on music consumption and production: a literature review //UK Centre for Data Ethics and Innovation Reports. — 2023.
- Ferraro A., Serra X., Bauer C. What is fair? Exploring the artists' perspective on the fairness of music streaming platforms //IFIP conference on human-computer interaction. — Cham: Springer International Publishing, 2021. — С. 562–584.
- Shakespeare D. et al. Exploring artist gender bias in music recommendation //arXiv preprint arXiv:2009.01715. — 2020.
- Tsintzou V., Pitoura E., Tsaparas P. Bias disparity in recommendation systems //arXiv preprint arXiv:1811.01461. — 2018.
- Mansoury M. et al. Feedback loop and bias amplification in recommender systems //Proceedings of the 29th ACM international conference on information and knowledge management. — 2020. — С. 2145–2148.
- Chen J. et al. Bias and debias in recommender system: A survey and future directions //ACM Transactions on Information Systems. — 2023. — Т. 41. — №. 3. — С. 1–39.
- Krishnan S. et al. A methodology for learning, analyzing, and mitigating social influence bias in recommender systems //Proceedings of the 8th ACM Conference on Recommender systems. — 2014. — С. 137–144.
- Klimashevskaja A. et al. A survey on popularity bias in recommender systems //User Modeling and User-Adapted Interaction. — 2024. — Т. 34. — №. 5. — С. 1777–1834.
- Ferraro A. et al. Artist and style exposure bias in collaborative filtering-based music recommendations //arXiv preprint arXiv:1911.04827. — 2019.
- Knees P., Ferraro A., Hubler M. Bias and feedback loops in music recommendation: Studies on record label impact // — CEUR-WS. org, 2022. — Т. 3268.
- Kowald D., Schedl M., Lex E. The unfairness of popularity bias in music recommendation: A reproducibility study //European conference on information retrieval. — Cham: Springer International Publishing, 2020. — С. 35–42.
- Jesse M., Bauer C., Jannach D. Intra-list similarity and human diversity perceptions of recommendations: the details matter: M. Jesse et al //User Modeling and User-Adapted Interaction. — 2023. — Т. 33. — №. 4. — С. 769–802.
- Do V., Usunier N. Optimizing generalized Gini indices for fairness in rankings //Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. — 2022. — С. 737–747.
- Punetha N., Jain G. Integrated Shannon entropy and COPRAS optimal model-based recommendation framework //Evolutionary Intelligence. — 2024. — Т. 17. — №. 1. — С. 385–397.
- Singh A., Joachims T. Fairness of exposure in rankings //Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery and data mining. — 2018. — С. 2219–2228.
- Burke R. Multisided fairness for recommendation //arXiv preprint arXiv:1707.00093. — 2017.

© Сеняткин Никита Станиславович (719042427@telegram.wappi)

Журнал «Современная наука: актуальные проблемы теории и практики»