

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

Научная статья / Original article



УДК 51-7:78

DOI 10.36683/ee244.4-13

JEL C45 C53 C65

EDN NXPFJU

Украинский К. В.

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ И ПРОГНОЗИРОВАНИЕ ПОПУЛЯРНОСТИ МУЗЫКИ: ОБЗОР ПОДХОДОВ И МЕТОДОВ

Украинский Константин Викторович

Европейский университет в Санкт-Петербурге (г. Санкт-Петербург, Россия), аспирант
e-mail: k.ukrainskii@eu.spb.ru
ORCID: 0009-0005-1688-3957

Konstantin V. Ukrainskii

European University at Saint-Petersburg (Saint-Petersburg, Russia), PhD student
e-mail: k.ukrainskii@eu.spb.ru
ORCID: 0009-0005-1688-3957

Научный руководитель

Раскина Юлия Владимировна

кандидат экономических наук, доцент
Европейский университет в Санкт-Петербурге (г. Санкт-Петербург, Россия), доцент факультета экономики
e-mail: raskina@eu.spb.ru
ORCID: 0000-0002-4663-9008
SPIN: 2047-0677

Scientific Supervisor

Yulia V. Raskina

Candidate of Economic Sciences, Associated Professor
European University at Saint-Petersburg (Saint-Petersburg, Russia), Associate Professor of Economics Faculty
e-mail: raskina@eu.spb.ru
ORCID: 0000-0002-4663-9008
SPIN: 2047-0677

В статье представлен комплексный обзор современных методов исследования популярности музыкальных произведений, включая статистические, временные и нейросетевые подходы. Рассматриваются регрессионные модели с фиксированными эффектами, модели выживания, нестационарные пуассоновские процессы и системы уравнений Лотки-Вольтерры, а также алгоритмы STL-декомпозиции и нейронные сети (LSTM-RPA). Обсуждаются их преимущества и ограничения в анализе динамики прослушиваний, влияния плейлистов и конкурентного взаимодействия жанров. Основное внимание уделено анализу их преимуществ и недостатков в контексте поставленных задач – прогнозирования долгосрочных изменений в популярности композиций, оценки влияния плейлистов и динамики конкуренции жанров. На основании проведённого анализа автор приходит к выводу, что для прогнозирования наиболее эффективно применение моделей LSTM-RPA благодаря их способности минимизировать накопление ошибок. Авторский вклад заключается в предложении нового подхода: адаптации гибридной методики, объединяющей нейросетевые модели и временные ряды, для учёта контекстуальных факторов, таких как влияние социальных трендов и маркетинговой активности, что позволяет существенно повысить универсальность и точность прогнозов.

The article presents a comprehensive review of modern methods of study of musical compositions popularity, including statistical, temporal and connectionist approaches. Regression models with fixed effects, survival models, nonstationary Poisson processes and systems of Lotka-Volterra equations, as well as STL decomposition algorithms and neural networks (LSTM-RPA) are considered. Their advantages and limitations in analyzing the dynamics of listening, the influence of playlists and competitive interaction of genres are discussed. The main attention is paid to the analysis of their advantages and disadvantages in the context of the tasks set — forecasting long-term changes in the popularity of compositions, assessing the impact of playlists and the dynamics of genre competition. On the basis of the analysis, the author concludes that the use of LSTM-RPA models is the most effective for forecasting due to their ability to minimize errors accumulation. The author contribution is in proposition of a new approach: the adaptation of hybrid methodology combining neural network models and time series for taking into account contextual factors such as influence of social trends and marketing activity that can significantly increase the versatility and accuracy of the forecasts.

Ключевые слова: музыкальная индустрия, анализ временных рядов, потоковые платформы, регрессионные модели, модели выживания, пуассоновский процесс, система Лотки-Вольтерры, LSTM-RPA, влияние плейлистов, конкуренция жанров.

Keywords: music industry, time series analysis, streaming platforms, regression models, survival models, Poisson process, Lotka-Volterra system, LSTM-RPA, playlist influence, genre competition.

Для цитирования: Украинский К. В. Математическое моделирование и прогнозирование популярности музыки: обзор подходов и методов // Экономическая среда. – 2024. – Т. 13, № 4. – С. 4-13. – <https://doi.org/10.36683/ee244.4-13>. – EDN NXPFJU.

For citation: Ukrainskii K.V. Mathematical Modeling and Forecasting of Music Popularity: an Overview of Approaches and Methods. *Economic environment*. 2024; 13 (4): 4-13. (In Russ.). – <https://doi.org/10.36683/ee244.4-13>. – URL: <https://www.elibrary.ru/NXPFJU>.

Введение

Музыкальная индустрия прошла через значительную трансформацию начиная с конца 1990-х годов, когда цифровизация начала кардинально менять способы производства и потребления музыки. Ранее, на протяжении многих десятилетий, основным способом распространения музыки было физическое владение продуктами – от виниловых пластинок до CD-дисков. Музыкальные коллекции были важным элементом потребительской культуры, отражая социальный статус и вкусы владельцев [1]. До 2000 года распространение музыкальных записей осуществлялось на физических носителях и совокупная доходность рынка достигала примерно 22 миллиарда долларов [2]. Появление новых цифровых форматов, таких как MP3 в сочетании с увеличением популярности CD- и MP3-плееров, значительно упростило копирование и обмен музыкальным контентом через нелегальные каналы. Этот способ стал популярен среди потребителей, поскольку они воспринимали его как быстрый и удобный вариант по сравнению с приобретением физических носителей [3]. Развитие технологии файлообмена (P2P) дополнительно усилило нелегальное распространение контента, что негативно сказалось на доходах музыкальной индустрии [4], вынудив индустрию адаптироваться к новой реальности [5].

В условиях массового распространения цифрового пиратства музыкальная индустрия столкнулась с необходимостью перестройки своих бизнес-моделей для сохранения прибыльности. Переход к «модели доступа» стал одним из важнейших ответов на вызовы цифровой эпохи, способствовав возникновению новых способов потребления музыкального контента. Поток сервисы, такие как Spotify, Apple Music, VK Music, предложили слушателям простой и законный доступ к широким музыкальным каталогам, изменив привычные механизмы взаимодействия с музыкой [6]. В рамках этой модели пользователи получают доступ к музыкальным библиотекам на условиях подписки или бесплатного прослушивания с рекламой, что позволило индустрии адаптироваться и сформировать новые рыночные стратегии [7].

В прошлом музыкальные чарты, служившие индикаторами популярности, играли роль своеобразных фильтров, через которые отбирались произведения для массовой аудитории [8]. Доступ к медиаканалам, таким как радио и телевидение, определял успех артиста, что делало процесс отбора непрозрачным и зависимым от субъективных решений так называемых «медиаторов» контента [9]. Современные потоковые платформы внесли существенные изменения в процессы распространения и потребления музыки, предложив новые механизмы, такие как плейлисты, персонализированные рекомендации и прямые прослушивания, которые заменили традиционные методы отбора музыки, позволяя слушателям формировать свои музыкальные библиотеки и тем самым обеспечивать персонализированный подход к прослушиванию [10].

Эти инновации предоставили уникальные возможности для продвижения музыки, однако они также привели к возникновению новых исследовательских вопросов, связанных с оценкой их влияния на популярность песен. Выявление ключевых факторов успеха и понимание динамики музыкальных предпочтений пользователей стали важными направлениями анализа в условиях растущей роли алгоритмов и плейлистов в формировании музыкальных трендов. Существующие подходы используют регрессионные модели, модели выживания, пуассоновские процессы и нейронные сети для оценки влияния различных факторов, таких как место в чарте, длительность пребывания в плейлисте и жанровая конкуренция. В данной работе представлен обзор существующих методов анализа, их математические основы, а также преимущества и ограничения каждого подхода.

Настоящее исследование направлено на оценку эффективности существующих моделей, включая LSTM-RPA, регрессионные модели с фиксированными эффектами и системы Лотки-Вольтерры, для прогнозирования популярности треков и анализа их поведения в условиях изменяющейся среды музыкальной индустрии.

Анализ существующих методов исследования

Понимание того, как различные механизмы потоковых платформ влияют на популярность музыкальных произведений, требует систематического подхода и применения совре-

менных аналитических инструментов. В литературе представлены различные подходы, направленные на исследование влияния плейлистов, алгоритмов рекомендаций и пользовательских предпочтений на динамику прослушиваний. В частности, значительный интерес вызывают регрессионные модели с фиксированными эффектами, методы временных рядов и модели машинного обучения, которые используются для оценки краткосрочных и долгосрочных эффектов включения песен в плейлисты.

Для каждого подхода выбран наиболее репрезентативный источник, отражающий ключевые закономерности и эволюцию методов в данной области. Такой выбор акцентирует теоретическую значимость и прикладную ценность результатов, демонстрируя связь между концептуальными основами и их практическим применением. Это обеспечивает целостное представление об исследуемой проблематике.

Панельные и разрывные регрессии

Одним из ключевых исследований в данной области, применяющих подход моделей панельных данных, является работа Агиара и Вальдфогеля [7], в которой решается задача оценки эффекта от включения песен в плейлисты для максимизации их популярности. Для оценки различных параметров популярности музыкальных композиций, таких как влияние включения в плейлисты на объёмы прослушиваний, влияние глобальных плейлистов, влияние изменения позиции, влияние рекомендательного плейлиста New Music Friday, применяются регрессионные модели с фиксированными эффектами, демонстрирующие потенциал моделей панельных данных для моделирования явлений в различных обстоятельствах.

Для анализа влияния включения песен в глобальные плейлисты Spotify использовалась регрессионная модель с фиксированными эффектами. Базовое уравнение:

$$S_{ict} = \gamma_t + \mu_{ic} + \pi_d + \epsilon_{ict}, \quad (1)$$

где S_{ict} – объём стриминга песни i в стране c в день t ,
 γ_t – эффект от времени, прошедшего с момента события (t) или до него ($t < 0$),
 μ_{ic} – фиксированный эффект песни для каждой страны в стране c ,
 π_d – эффект дня недели,
 ϵ_{ict} – ошибка модели.

На примере плейлиста Today's Top Hits модель показала, что добавление песни увеличивает нормализованные стримы в среднем на 3.34 единицы (стандартная ошибка 0.28).

В статье используется инструментальный подход для устранения эндогенности, в котором на первом шаге ранг песни моделируется через размер рынка (количество стримов) в конкретной стране от общего числа прослушиваний, а на втором шаге для оценки влияния ранга на прослушивания используется инструментальная переменная. Полученные оценки (-0.048 и 0.069) устраняют смещение, но с большими стандартными ошибками (0.023 и 0.033), что указывает на неопределённость инструмента.

Для оценки влияния места в глобальном плейлисте Global Top 50 на последующие прослушивания использовался метод дискретной разрывной регрессии. Для анализа прослушиваний между соседними местами (рангами) применялось уравнение:

$$\log\left(\frac{S_{rt}}{S_{r-1,t}}\right) = \theta_r + \epsilon_{rt}, \quad (2)$$

где $S_{r,t}$ и $S_{r-1,t}$ – количество стримов песни на текущем и предыдущем ранге,
 θ_r – коэффициент, отражающий процентное уменьшение стримов при переходе с ранга $r - 1$ на ранг r ,
 ϵ_{rt} – ошибка модели.

Результаты показали, что переход с ранга 50 на 51 сопровождается резким снижением стримов на 6 %, тогда как для соседних рангов снижение составляет около 2 %. Это указывает,

что нахождение в плейлисте Global Top 50 добавляет примерно 4 % к количеству прослушиваний.

Оценка влияния плейлиста рекомендаций New Music Friday на попадание в Today's Top Hits оценивалась при помощи модели с фиксированными эффектами:

$$D_{200,ic} = \alpha_r \delta_{r,ic} + \mu_c + \eta_i + \epsilon_{ic}, \quad (3)$$

где $D_{200,ic}$ – бинарная переменная, показывающая, появилась ли песня i в стране c в Today's Top Hits,

α_r – коэффициент, показывающий, как вероятность успеха меняется в зависимости от ранга r в плейлисте,

$\delta_{r,ic}$ – индикаторная переменная, равная 1, если композиция занимает ранг r в листе рекомендаций New Music Friday,

μ_c – фиксированный эффект от страны,

η_i – фиксированный эффект качества песни,

ϵ_{ic} – ошибка модели.

Результаты показали, что песни с рангом 1–5 в плейлисте New Music Friday имеют вероятность появления в топ-200 на 50 % выше, чем песни с рангом 50. Для рангов 6–10 вероятность снижается до 18 %, а для рангов 11–30 эффект становится статистически незначимым.

Статья демонстрирует, что предложенные регрессионные подходы, включая модели с фиксированными эффектами и разрывной регрессией, позволяют оценивать влияние плейлистов Spotify на объёмы стриминга, однако модель ограничена предположением о линейности эффектов. Кроме того, разрывная регрессия предполагает строгую сопоставимость соседних рангов, что не всегда выполняется. Модель не учитывает возможные взаимодействия между эффектами включения и исключения из плейлистов и динамикой стриминга, а также не описывает долгосрочные последствия для популярности песен вне Spotify. Таким образом, подход обеспечивает ценную интерпретацию краткосрочного влияния плейлистов, но требует расширения для учёта сложных временных и структурных факторов.

Применение методологии стохастических процессов

В работе М. Харрис и др. [11] при помощи модели стохастического процесса, опирающейся на методологию стохастических точечных процессов, был проведён анализ динамики популярности песен в глобальном плейлисте Spotify Top 200 для описания процесса потокового прослушивания. Основная задача заключалась в выявлении закономерностей поведения песен в рейтинге, их рангов, длительности нахождения в списке и характеристик ежедневных прослушиваний. Авторы установили, что среднее число ежедневных прослушиваний подчиняется степенной зависимости от ранга песни, а наиболее высокие ранги достигаются крайне редко. Также было показано, что популярные песни обладают большей долговечностью, а структура ежедневного числа прослушиваний часто характеризуется скачками, вызванными внешними событиями, и последующим затуханием. Для описания этих процессов была предложена модель нестационарного пуассоновского процесса с временно-зависимой интенсивностью, способная имитировать наблюдаемые скачки и затухания [11].

Пусть для каждой композиции существует точечный процесс $\{N(t) \mid t \geq 0\}$, $N(0) = 0$, отражающий количество прослушиваний композиции до момента $t \geq 0$, где $N(t)$ – нестационарный пуассоновский процесс с интенсивностью $\lambda(t)$, заданный как:

$$\lambda(t) = \lambda + \beta_0 \theta_0 e^{-\beta_0 t} + \beta_1 \theta_1 e^{-\beta_1 (t-a)} \mathbb{1}_{t \geq a}, \quad (4)$$

где $\lambda \geq 0$ – базовая интенсивность, отражающая уровень прослушивания в «спокойной» фазе,

$\theta_0 > 0, \theta_1 > 0$ – амплитуда интенсивности процесса,

$\beta_0 > 0, \beta_1 > 0$ – коэффициенты экспоненциального затухания,

$a \geq 0$ – момент времени внешнего события, вызывающего дополнительный скачок.

Первый член $\beta_0 \theta_0 e^{-\beta_0 t}$ описывает скачок популярности при дебюте композиции, $\beta_1 \theta_1 e^{-\beta_1(t-a)}$, описывает изменения, вызванные внешними событиями в момент a . Логарифм функции максимального правдоподобия для наблюдаемого числа потоков n_i за T дней:

$$L(\beta_0, \beta_1, \theta_0, \theta_1, \lambda) = \sum_{i=1}^T [n_i \log \lambda_i - \lambda_i - \log(n_i!)], \quad (5)$$

где:

$$\lambda_i = \lambda \Delta + \theta_0 (e^{-\beta_0 \Delta(i-1)} - e^{-\beta_0 \Delta i}) + \theta_1 (e^{-\beta_1 (\Delta(i-1)-a)} - e^{-\beta_1 (\Delta i - a)}). \quad (6)$$

Для анализа взаимосвязей между песнями в Spotify Top 200 применён алгоритм кластеризации -средних (k -Means). Основой группировки послужили два параметра, полученные из модели пуассоновского процесса:

- коэффициент убывания популярности β , характеризующий экспоненциальное затухание ежедневных потоков прослушивания. Этот параметр отражает долгосрочную популярность песни. Низкие значения β свидетельствуют о длительной популярности песни, в то время как высокие значения указывают на быстрый спад;

- коэффициент детерминации R^2 , измеряющий точность соответствия модели реальным данным. Этот параметр помогает различать песни, динамика популярности которых хорошо описывается экспоненциальным затуханием.

Метод кластеризации -средних демонстрирует высокую практическую ценность для анализа музыкальных данных, однако использование только двух параметров (β и R^2) может упускать многие важные характеристики песен и подходит только для композиций с экспоненциальной динамикой.

Модели длительности состояний

Ключевой работой, использующей модели длительности состояний, является работа Кайманна, Таннеберга и Кокса [12] для анализа продолжительности нахождения композиций в глобальном плейлисте Spotify Global Top 200. Авторы представляют время пребывания трека i в чарте на момент времени t в виде следующей формулы:

$$S_{it} = f(M_i, C_{aoijt}, D_i, P_i, A_{aij}, T_{it}), \quad (7)$$

где M_i – бинарная переменная, указывающая, был ли трек i выпущен крупным лейблом, C_{aoijt} – конкуренция трека i в чарте в момент t , включая количество других треков того же артиста j ,

o – количество треков других артистов в чарте за тот же период,

D_j – переменные диффузии, такие как позиция трека при старте i , разница в днях между датой релиза трека i и появлением в чарте,

P_i – характеристики музыкальной композиции,

A_{aij} – характеристики артиста a , такие как пол, опыт артиста, количество предыдущих треков j , попавших в чарт,

T_{it} – временные характеристики, месячные тренды, признак возвращения в плейлист.

Для учёта влияния объясняющих переменных на время нахождения трека в чарте используется модель ускоренного времени (AFT):

$$\ln(T) = x\beta + \epsilon, \quad (8)$$

где T – время нахождения трека в чарте,

x – вектор объясняющих переменных, определённых в линейной модели,

β – вектор коэффициентов модели, показывающий степень влияния факторов,

ϵ – ошибка модели.

Параметры β интерпретируются как логарифмы коэффициентов ускорения, то есть величины, пропорциональной времени нахождения трека в чарте. Например, положительное значение β_j означает увеличение времени выживания при росте X_j .

Исследование выявило значимые переменные: поддержка крупных лейблов (+34.9 %), внутренняя конкуренция (−4.7 % на трек), стартовая позиция (−0.016 % за каждую единицу) и время до первого появления в чартах (+0.005). Преимущество модели – учет нелинейной зависимости через лог-логистическое распределение, недостаток – невозможность корректного учёта эндогенности и субъективного качества трека.

Модели популяционной динамики

В работе Падилла и др. [13] для анализа конкуренции двух музыкальных направлений, ОРМ и К-Пор, была использована система уравнений Лотки-Вольтерры (LV-модель). Уравнения моделируют взаимодействие между жанрами, где каждый жанр рассматривается как «вид». Система уравнений имеет вид:

$$\frac{do(t)}{dt} = a_1 o(t) + b_1 o^2(t) + c_1 k(t)o(t), \quad (9)$$

$$\frac{dk(t)}{dt} = a_2 k(t) + b_2 k^2(t) + c_2 o(t)k(t), \quad (10)$$

где, $o(t)$ и $k(t)$ – число потоков для жанров ОРМ и К-Пор соответственно в момент времени t , a_1 и a_2 – параметры, описывающие экспоненциальный рост жанров в отсутствие конкуренции;

b_1 и b_2 – параметры, моделирующие внутривидовые взаимодействия (взаимопомощь или конкуренция внутри жанра),

c_1 и c_2 – параметры, описывающие межвидовые взаимодействия (влияние одного жанра на рост другого).

Тип взаимодействия определяется знаками параметров c_1 и c_2 , например: если оба параметра отрицательных, то такой тип определяется как чистая конкуренция, оба жанра подавляют друг друга, а положительные знаки указывают на «взаимопомощь», т. е. жанры усиливают друг друга.

На следующем шаге методом S-ARIMA производится прогноз общего числа потоков $\hat{S}$ для последующего разделения по жанрам. Параллельно рассчитывается вклад каждого жанра в общий поток: $x_o = \frac{S_o}{S}$, $x_k = \frac{S_k}{S}$. К полученным временным рядам применяется STL (Seasonal and Trend Decomposition using Loess) декомпозиция

$$x(t) = x_{\text{trend}}(t) \cdot x_{\text{seasonal}}(t) \cdot x_{\text{random}}(t), \quad (11)$$

после чего из данных исключается сезонная компонента

$$x_f(t) = x_{\text{trend}}(t) \cdot x_{\text{random}}(t). \quad (12)$$

Отфильтрованные значения применяются для расчёта LV модели. Одновременно методом простого среднего рассчитывается сезонная компонента. Полученные результаты умножаются на общее количество потоков

$$\widehat{S}_o = \hat{S} \cdot \widehat{x}_o, \quad (13)$$

$$\widehat{S}_k = \hat{S} \cdot \widehat{x}_k. \quad (14)$$

В статье показано, что взаимодействие между жанрами варьировалось по периодам: хищник-жертва (периоды 1 и 3) и чистая конкуренция (период 2). В первом периоде К-Пор

доминировал с параметром $c_2 = 1.25$, тогда как в период два взаимодействие ослабло ($c_1 = -0.27$ и $c_2 = -0.29$). Прогнозы агрегированных потоков имели $R^2 > 0.98$ для всех периодов, что указывает на высокую точность модели. MAPE для ОРМ варьировался от 0.74 % (период 2) до 4.9 % (период 3), а для К-Рор был выше из-за новых релизов, достигая 9.47 % (период 1). RMSE оставался в пределах 38,100–350,600 потоков для ОРМ и 53,860–98,810 для К-Рор. Новый релиз в период 1 значительно увеличил ошибки прогнозирования К-Рор, что подтверждает чувствительность модели к резким всплескам данных, вызванным новыми релизами и сезонными эффектами, что увеличивает ошибки прогнозов.

Модели временных рядов

Одна из оригинальных работ, анализирующая временные ряды, статья Сюй Вей [14], направлена на прогнозирование объема прослушиваний артистов с использованием декомпозиции временных рядов на тренд, сезонность и случайные отклонения, а также оптимизации выбора методов прогноза на основе оценки нормализованной дисперсии. Для улучшения точности предложены алгоритмы кодирования трендов и сопоставления субпоследовательностей, учитывающие резкие изменения данных, такие как выпуск новых альбомов [14].

Модель использует следующие входные данные:

$y_{a,t}$ – фактический объем прослушиваний для артиста a на день t ,

$t \in T$, где T – общее количество наблюдаемых дней,

$a \in A$, где A – множество всех артистов.

На основе среднего объема прослушиваний рассчитываются кодированные тренды для каждого артиста: основной тренд и инкрементальный тренд. Каждый временной ряд $y_{a,t}$ декомпозируется на три компоненты: тренд $T_a(t)$, сезонность $S_a(t)$ и случайные отклонения $R_a(t)$, общее представление тренда:

$$y_{a,t} = T_a(t) + S_a(t) + R_a(t). \quad (15)$$

Для оценки компонентов используется STL-декомпозиция. Для каждого артиста выбирается оптимальный метод прогнозирования из множества M , включающего скользящее среднее за k дней, медиану последних k дней, экспоненциальное сглаживание. Каждый метод $m \in M$ оценивается с использованием функции точности S :

$$S = \sum_{a \in A} w_a V_a, \quad (16)$$

где $w_a = \frac{1}{\sqrt{\sum_{t=1}^T y_{a,t}^2}}$ – вес артиста,

$V_a = 1 - \frac{\sum_{t=1}^T (\hat{y}_{a,t} - y_{a,t})^2}{\sum_{t=1}^T y_{a,t}^2}$, нормализованная дисперсия метода m для артиста a .

Оптимальный метод для каждого артиста выбирается по методу $\arg\max$:

$$m_a^* = \arg \max_{m \in M} S_m, \quad (17)$$

$$S_m = \sum_{a \in A} w_a V_{a,m}. \quad (18)$$

Для артистов с резкими изменениями в динамике (например, выпуск нового альбома) используется метод субпоследовательностей. Алгоритм идентифицирует последние k дней временного ряда и находит схожие исторические паттерны у других артистов. Выбор лучшего паттерна проводится с помощью метрики Евклидова расстояния.

Выбранная модель демонстрирует высокую точность и гибкость. Средняя нормализованная дисперсия $V_a = 0.92$ для стабильных артистов, а применение метода субпоследовательностей позволило снизить ошибки прогнозирования на 15 % для артистов с резкими из-

менениями в объёмах прослушиваний. Итоговая оценка модели согласно функции точности $S = 0.88$ на 10 % превосходит традиционные методы, такие как ARIMA и экспоненциальное сглаживание. Преимуществами предложенной модели являются адаптивность к индивидуальным особенностям временных рядов, учёт сезонных трендов и способность корректно обрабатывать внезапные изменения, такие как выпуск нового альбома. Однако модель обладает высокой вычислительной сложностью, чувствительна к параметрам (длине субпоследовательностей k и количеству ближайших соседей N) и не учитывает внешние факторы, такие как маркетинговая активность и социальные тренды.

Применение нейронных сетей

Последней хотелось бы рассмотреть модель, основанную на работе с нейронными сетями, авторов Ли и др. [15]. Работа посвящена прогнозированию долгосрочных трендов популярности музыки, основанному на исторических данных о прослушиваниях, загрузках и коллекционировании треков. Авторы разработали алгоритм LSTM Rolling Prediction Algorithm (LSTM-RPA), который преобразует задачу долгосрочного прогноза в последовательность краткосрочных прогнозов, что позволяет улучшить точность. Эксперименты подтверждают превосходство предложенного подхода над традиционными моделями (ARIMA, SMA) и нейронными сетями (LSTM, BiLSTM, GRU, RNN). Модель описывается следующими уравнениями:

$$f_t = \sigma(W_f \cdot h_{t-1} + W_f \cdot x_t + b_f), \quad (19)$$

$$i_t = \sigma(W_i \cdot h_{t-1} + W_i \cdot x_t + b_i), \quad (20)$$

$$\tilde{C}_t = \tanh(W_c \cdot h_{t-1} + W_c \cdot x_t + b_c), \quad (21)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \quad (22)$$

$$o_t = \sigma(W_o \cdot h_{t-1} + W_o \cdot x_t + b_o), \quad (23)$$

$$h_t = o_t \cdot \tanh(C_t), \quad (24)$$

где f_t – «забывающий» модуль, отвечает за сохранение релевантной информации,
 i_t – модуль добавления новой информации,
 $\tilde{C}_t$ – обновлённые состояния,
 C_t – память блока,
 h_t – скрытое состояние, передающееся дальше,
 σ_t – функция активации,
 W_i, W_f, W_c, W_o – веса матриц,
 b_i, b_f, b_c, b_o – смещения.

Алгоритм делит задачу долгосрочного прогноза на несколько краткосрочных этапов. Алгоритм строит последовательность предсказаний, используя прошлые значения и текущий прогноз как вход для следующего шага. Математическая формализация:

$$X_t^* = X_{t-1} [x'_1, x'_2, \dots, x'_l] + Y_t [y_1, y_2, \dots, y_{p-1}], \quad (25)$$

$$Y_{t+1}^* = \text{unit}(X_t^*), \quad (26)$$

где X_{t-1} – входная последовательность для времени $t - 1$,
 Y_t – результаты предсказания на t -й момент времени,
 l – длина скользящего окна,
 p – длина входной последовательности,
 Y_{t+1}^* – предсказанные значения на $t + 1$, unit – обученная LSTM модель.

Алгоритм LSTM-RPA продемонстрировал высокую эффективность в долгосрочном прогнозировании музыкальной популярности, увеличив F-индекс на 10.67 % – 18.52 % и снизив среднюю ошибку на 32.64 % – 2.88 % по сравнению с традиционными и базовыми нейросетевыми моделями. Его основное преимущество – преобразование долгосрочного прогноза в

серию краткосрочных, что снижает накопление ошибок, а также возможность работы с несколькими признаками. Однако модель чувствительна к выбору гиперпараметров, требует высоких вычислительных ресурсов и зависит от качества данных, что ограничивает её применение в условиях шумных или неполных наборов данных.

Выводы

Анализ существующих методов исследований показывает, что современные подходы к изучению музыкальных трендов и популярности композиции разнообразны и основываются на статистических, временных и нейронных моделях. Регрессионные модели с фиксированными эффектами [7] доказали свою ценность в оценке краткосрочного влияния плейлистов на стримы, однако ограничены предположением о линейности эффектов и эндогенности рангов. Модели пуассоновского процесса и выживания [11] позволяют анализировать временную динамику популярности и длительность нахождения в чартах, но требуют расширения для учёта внешних факторов и взаимодействий между параметрами. LV-модель эффективно описывает конкурентное поведение музыкальных жанров, но её применение ограничено конкуренцией между жанрами. STL-декомпозиция и методы временных рядов [14] показали высокую точность прогнозирования благодаря учёту сезонных трендов и резких изменений, хотя их вычислительная сложность ограничивает масштабирование. LSTM-RPA выделяется среди нейронных подходов, демонстрируя значительное улучшение точности долгосрочного прогнозирования за счёт разбиения задач на короткие этапы, но остаётся чувствительным к качеству данных и выбору гиперпараметров.

Основным выводом работы является необходимость интеграции преимуществ различных подходов в рамках гибридной методологии, которая способна решить выявленные ограничения каждого из методов. Автор предлагает адаптировать гибридный подход, сочетающий нейросетевые модели (LSTM-RPA) для работы с нелинейными зависимостями и краткосрочным прогнозированием с методами временных рядов (STL-декомпозиция) для учёта сезонности и резких изменений, а также моделями выживания для анализа длительности нахождения треков в чартах. В дополнение к этому предлагается учитывать контекстуальные факторы, такие как влияние социальных трендов, маркетинговой активности и позиции трека в плейлистах, через дополнительные переменные в модели. Такой подход позволяет не только улучшить краткосрочное прогнозирование популярности треков, но и обеспечить универсальность для анализа долгосрочных трендов, включая конкуренцию жанров.

Применение предложенного подхода может существенно повысить точность прогнозов, сделать их более адаптивными к изменениям данных и обеспечить учёт сложных взаимодействий между ключевыми параметрами музыкальной индустрии. Дальнейшие исследования могут быть направлены на эмпирическую проверку предложенной методики и её масштабирование для работы с большими потоковыми данными.

Список источников:

1. Wikström, P. The music industry: music in the cloud : Digital media and society series. The music industry / P. Wikström. – Cambridge ; Malden, MA : Polity, 2009. – 204 p.
2. IFPI Global Music Report 2024 // IFPI, 2024. – URL: https://ifpi-website-cms.s3.eu-west-2.amazonaws.com/IFPI_GMR_2024_State_of_the_Industry_db92a1c9c1.pdf.
3. Vaccaro, V. L. The Evolution of Business Models and Marketing Strategies in the Music Industry / V. L. Vaccaro, D. Y. Cohn // International Journal on Media Management. – 2004. – Vol. 6, Issue 1-2. – P. 46-58. – DOI 10.1080/14241277.2004.9669381.
4. McKenzie, J. Digital piracy / J. McKenzie. // Handbook of Cultural Economics, Third Edition / eds. R. Towse, T. Navarrete Hernández. – Edward Elgar Publishing, 2020. – DOI 10.4337/9781788975803.00031.
5. Farchy, J. D. Artificial intelligence / J. Farchy, J. Denis // Handbook of Cultural Economics, Third Edition / eds. R. Towse, T. Navarrete Hernández. – Edward Elgar Publishing, 2020. – DOI 10.4337/9781788975803.00010.
6. Grote, F. Mark Mulligan: Awakening. The Music Industry in the Digital Age. London (MIDIa Research) 2015, 332 Seiten / F. Grote. // Zeitschrift für Kulturmanagement. – 2016. – Vol. 2. – P. 177-182. –

DOI 10.14361/zkmm-2016-0214.

7. Aguiar, L. Platforms, Power, and Promotion: Evidence from Spotify Playlists / L. Aguiar, J. Waldfogel // The Journal of Industrial Economics. – 2021. – Vol. 69, Issue 3. – P. 653-691. – DOI 10.1111/joie.12263.

8. Hirsch. The Structure of the Popular Music Industry: The Filtering Process by which Records are Preselected for Public Consumption / Hirsch // Institute for Social Research, The University of Michigan. – 1973.

9. Ordanini, A. Selection models in the music industry: How a prior independent experience may affect chart success / A. Ordanini // Journal of Cultural Economics. – 2006. – Vol. 30. – P. 183-200. – DOI 10.1007/s10824-006-9013-8.

10. Morris, J. W. Control, curation and musical experience in streaming music services / J. W. Morris, D. Powers // Creative Industries Journal. – 2015. – Vol. 8, Issue 2. – P. 106-122. – DOI 10.1080/17510694.2015.1090222.

11. Analyzing the Spotify Top 200 Through a Point Process Lens / M. Harris, B. Liu, C. Park [et al.] // arXiv. – 2019. – DOI 10.48550/arXiv.1910.01445.

12. Kaimann, D. “I will survive”: Online streaming and the chart survival of music tracks / D. Kaimann, I. Tanneberg, J. Cox. // Managerial and Decision Economics. – 2021. – Vol. 42, Issue 1. – P. 3-20. – DOI 10.1002/mde.3226.

13. An application of the Lotka-Volterra model with time series analysis to forecast spotify streams of two genres / J. R. F. Padilla, E. D. Baniaga, R. C. Addawe, J. P. T. Viernes. // Proceedings of the International Conference on Mathematical Sciences and Technology 2022 (MATHTECH 2022): Navigating the Everchanging Norm with Mathematics and Technology. 13–15 September 2022 Penang, Malaysia, 2024. – P. 070001. – DOI 10.1063/5.0192499.

14. Music popular trends prediction based on time series / Yu W. [et al.] // Computer Engineering & Science. – 2018. – Vol. 40, Issue 9. – P. 1703-1709. (in Chinese.) – URL: <http://joces.nudt.edu.cn/CN/abstract/abstract15746.shtml>.

15. LSTM-RPA: A Simple but Effective Long Sequence Prediction Algorithm for Music Popularity Prediction. LSTM-RPA / K. Li, M. Li, Y. Li, M. Lin // arXiv. – 2021. – DOI: 10.48550/arXiv.2110.15790.

Статья поступила в редакцию / Received: 25.11.2024

Принята к публикации / Accepted: 18.12.2024

Дата выхода в свет / Date of publication: 25.12.2024