

РАСПРЕДЕЛЕНИЕ ДНЕВНОГО ПРОМО-ЭФФЕКТА НА ОСНОВЕ ЛОКАЛЬНОЙ И ИСТОРИЧЕСКОЙ ДИНАМИКИ

ALLOCATING THE DAILY PROMOTIONAL EFFECT BASED ON LOCAL AND HISTORICAL DYNAMICS

A. Bystrov

Summary. This article addresses the problem of detailed allocation of the cumulative promotional effect across the days of a promotion in retail trade and the fast-food industry. The aim of the study is to develop a hybrid methodology that combines local dynamics (daily sales forecasts) and historical patterns of promotional effect distribution. The proposed approach is based on calculating a «local» share determined from the sales forecast for each day of the promotion and using an averaged «historical» profile defined by typical patterns for promotions of various durations. The mechanism for blending the two sources of information is implemented through the parameter α , which allows for optimal adjustment of the final sales increment already calculated by global models (e.g., XGBoost). The methodology includes comparing three distribution options—purely local, purely historical, and hybrid—with effectiveness evaluated using the WAPE metric. Experimental results based on real data from a fast-food chain demonstrate that the hybrid approach reduces forecasting error to 24.7 %, significantly outperforming alternative methods. The study also emphasizes the potential for integrating the proposed methodology into corporate information systems and using modern machine learning algorithms and neural networks to further improve the accuracy of detailed forecasts.

Keywords: demand forecasting, promotional effect, daily distribution, hybrid profile, local dynamics, historical profile, information systems, machine learning, neural networks.

Быстров Александр Игоревич

Аспирант, ФГБОУВО «Российская академия
народного хозяйства и государственной службы
при Президенте Российской Федерации», Москва, Россия
alexandr.jri.bystrov@yandex.ru

Аннотация. В данной статье рассматривается задача детального распределения совокупного промо-эффекта по дням проведения акции в розничной торговле и индустрии быстрого обслуживания. Цель исследования — разработка гибридной методики, объединяющей локальную динамику (ежедневные прогнозы продаж) и исторические паттерны распределения промо-эффекта. Предлагаемый подход основан на расчете «локальной» доли, определяемой на основе прогноза продаж за каждый день акции, и использовании усредненного «исторического» профиля, заданного типовыми паттернами для акций различной длительности. Механизм смешивания двух источников информации осуществляется через параметр α , позволяющий оптимально скорректировать итоговый прирост продаж, уже рассчитанный глобальными моделями (например, XGBoost). Методология включает сравнение трех вариантов распределения — чисто локального, чисто исторического и гибридного — с оценкой эффективности по метрике WAPE. Экспериментальные результаты, полученные на основе реальных данных сети быстрого питания, демонстрируют, что гибридный подход снижает ошибку прогнозирования до 24.7 %, что значительно превосходит альтернативные методы. Исследование также подчеркивает перспективность интеграции предложенной методики в корпоративные информационные системы и использования современных алгоритмов машинного обучения и нейронных сетей для дальнейшего повышения точности детального прогноза.

Ключевые слова: прогнозирование спроса, промо-эффект, дневное распределение, гибридный профиль, локальная динамика, исторический профиль, информационные системы, машинное обучение, нейронные сети.

Введение

В условиях современных розничных сетей и индустрии быстрого обслуживания (QSR) промо-акции (скидки, «2+1», купонные предложения, акционные наборы и др.) стали неотъемлемой частью маркетинговой стратегии, позволяя стимулировать спрос и конкурировать на рынке. При этом, как отмечено в ряде исследований [1, 2, 3], прогнозирование продаж во время акций усложняется из-за повышенной волатильности спроса и множества взаимодействующих факторов (сезонность, региональные особенности, механика промо и т.д.).

Особое внимание уделяется распределению итогового (суммарного) промо-эффекта по дням. Если акция

длится несколько дней, важно понять, как именно «раскладывается» прирост продаж на каждый день. Практика показывает, что для ряда промо (например, «быстрые скидки») всплеск приходится на первые дни, тогда как накопительные акции могут давать максимальный эффект ближе к концу. При этом необходимо одновременно учитывать локальные прогнозы и усредненные исторические паттерны.

Цель данной статьи — рассмотреть гибридную методику дневного распределения прироста, совмещающую информацию о «локальной» динамике (на уровне дня) и обобщенном «историческом» профиле. Такой подход позволяет снизить суммарную ошибку, учитывая как текущее состояние спроса, так и накопленный исторический опыт по акциям.

Обзор литературы и методологических подходов

Большинство существующих методов ориентировано на прогнозирование общего объема продаж за промо-период (например, неделю или две) без детальной разбивки по дням. Однако при планировании логистики, складских операций и графиков персонала важна именно подневная точность. Ошибки при детальном прогнозировании влекут риск «недопрогноза» или «перепрогноза» в конкретные даты, что негативно отражается на эффективности использования ресурсов [1, 2].

Современные работы [2, 3, 4] подчеркивают рост значимости методов машинного обучения (CatBoost, XGBoost, нейронные сети) при анализе больших исторических массивов данных для прогнозирования спроса и выявления ключевых факторов. Например, в [3] описано, как учет макроэкономических индикаторов повышает точность розничных прогнозов, а в [4] приводится алгоритм XGBoost, позволяющий гибко учитывать внешние влияния и избегать переобучения. Тем не менее, даже при высоком качестве итоговых ML-прогнозов, остается нерешенной задача посуточной детализации — ведь единое значение Δ_{total} еще не дает готового распределения продаж по каждому дню акции.

Существует два крайних подхода:

1. Чисто локальный: итоговый прирост Δ_{total} распределяется пропорционально долям:

$$\Delta_{total_j} = \frac{predicted_i}{\sum_j predicted_j},$$

где $predicted_i$ — прогноз baseline-модели на конкретный день акции, а его сумма по $predicted_j$ складывается из суммы всех дней акции. Преимущество состоит в учете свежей информации; недостаток — возможная шумность локальных прогнозов.

2. Чисто исторический: используется усредненный «профиль» $\{p_1, \dots, p_i\}$ (с суммой, равной 1) для акций длиной L дней. Тогда:

$$hist_i = p_i \times total,$$

где p_i — средний вес дня среди акций с одинаковой длительностью. Такой профиль стабилен и отражает накопленный опыт, но не учитывает специфику текущей акции (например, масштаб скидки, параллельные предложения и др.).

В ряде работ упоминается о комбинировании обоих методов с помощью параметра $\alpha \in [0, 1]$:

$$adjusted_share_i = \alpha \times \frac{predicted_i}{\sum_j predicted_j} + (1 - \alpha) \times p_i,$$

$$\Delta_i = adjusted_share_i \times \Delta_{total},$$

где $adjusted_share_i$ — это доля от общего прогноза Δ_{total} в конкретный день акции. Данный подход дает возможность «смешать» локальные и исторические данные, снижая итоговую погрешность.

Материалы и методы исследования

Постановка задачи и алгоритм гибридного распределения

Общие обозначения:

- L — длина промо-периода в днях.
- Δ_{total} — итоговый прирост продаж по акции (предварительно рассчитанный глобальной моделью).
- $predicted_i$ — локальный прогноз продаж по дню i .
- p_i — усредненный исторический профиль для акций длиной L дней, при этом $\sum p_i = 1$.

Требуется найти Δ_i — дневной прирост для каждого i с учетом двух источников информации.

Формула смешанного распределения: сначала вычислим «локальную» долю:

$$local_share_i = \begin{cases} \frac{predicted_i}{\sum_j predicted_j}, & \text{если } \sum_j predicted_j \neq 0, \\ 0, & \text{иначе} \end{cases},$$

Затем введем «смешанную» долю:

$$adjusted_share_i = \alpha \times local_share_i + (1 - \alpha) \times p_i$$

Итоговый прирост по дню:

$$\Delta_i = adjusted_share_i \times \Delta_{total}.$$

Обработка особых случаев: если $\sum predicted_j = 0$, то локальное распределение не работает. В таком случае разумно прибегнуть либо к чисто историческому профилю, либо (при наличии другой бизнес-логики) установить $\Delta_{i=0}$. Выбор конкретной стратегии зависит от бизнес-правил и свойств данных.

Реализация в виде Python-кода и интеграция в информационные системы

Предложенная методика легко встраивается в корпоративные ИТ-ландшафты [1, 2]. Ниже на рисунке 1 приведен упрощенный пример на Python/pandas:

Полученный DataFrame можно визуализировать или вывести в корпоративную систему. Как отмечено в [1, 2], ключевым элементом является удобный интерфейс для автоматизации и анализа, позволяющий менеджерам

```

alpha = 0.5 # коэффициент смещения
list_of_promo_periods = []

for (key, loc, prod), df_group in regression_predictions.groupby(
    ["promo_key", "pbo_location_id", "product_id"]
):
    # Общий промо-прирост, рассчитанный глобальной моделью (XGBoost и т.п.)
    total_increase = df_group["y_pred"].iloc[0]

    raw_rows = results_df[
        (results_df["promo_key"] == key) &
        (results_df["pbo_location_id"] == loc) &
        (results_df["product_id"] == prod)
    ]
    promo_period = raw_rows[raw_rows["is_promo_day"]].copy()

    # Сумма локальных прогнозов
    sum_pred = promo_period["predicted"].sum()

    # Длина L и исторический паттерн (предположим, хранится в словаре)
    L = (promo_period["ds"].max() - promo_period["ds"].min()).days + 1
    hist_profile = profile_dict.get(L, None) # массив p_i

    if sum_pred != 0:
        local_share = promo_period["predicted"] / sum_pred
        if hist_profile is not None and len(hist_profile) >= L:
            # Гибридная доля
            adjusted_share = alpha * local_share.values + (1 - alpha) * hist_profile
            promo_period["promo_to_add_daily"] = adjusted_share * total_increase
        else:
            # Если исторический профиль отсутствует, fallback на локальный
            promo_period["promo_to_add_daily"] = local_share * total_increase
    else:
        # sum_pred = 0 => fallback
        promo_period["promo_to_add_daily"] = 0

    list_of_promo_periods.append(promo_period)

# Итоговый DataFrame можно сохранить в БД или использовать для аналитики
final_df = pd.concat(list_of_promo_periods, ignore_index=True)

```

Рис. 1. Пример реализации алгоритма

оперативно изучать результаты распределения промо-эффекта.

Результаты

Для демонстрации были взяты реальные данные одной из сетей быстрого питания (десятки промо). Сначала был рассчитан Δ_{total} методом XGBoost [4] с учетом исторических продаж, ценовых факторов, сезонности и т. д. Далее сформировали исторические профили p_i для основных длительностей акций (3, 5 и 7 дней).

Сопоставлялись:

1. (A) Локальное ($\alpha=1$);
2. (B) Историческое ($\alpha=0$);
3. (C) Гибрид ($\alpha=0.5$).

Ошибку оценивали с помощью WAPE (взвешенная абсолютная процентная ошибка) при сравнении фактического и рассчитанного дневного прироста. Итоги суммированы в таблице ниже.

Таблица 1.

Сравнение трех подходов

Метод	WAPE, %
(А) Чисто локальный ($\alpha=1$)	27.3
(В) Чисто исторический ($\alpha=0$)	25.2
(С) Гибрид ($\alpha=0.5$)	24.7

Из данных видно, что гибридный вариант (С) дает наиболее низкую суммарную ошибку WAPE, поскольку учитывает одновременно и специфику текущей акции, и усредненные исторические закономерности.

Обсуждение

В современных исследованиях для расчета общего Δ_{total} активно применяются методы машинного обучения [2, 3, 4], такие как XGBoost, CatBoost, нейронные сети (в том числе LSTM). Авторы [3] подчеркивают важность учета экзогенных переменных (макроэкономических, сезонных и т. д.), а в [4] представлена методика оптимизации гиперпараметров XGBoost. Однако даже качественная ML-модель, предсказывающая суммарный прирост, не решает задачу «разбивки» результатов по дням. Поэтому предложенный в статье гибридный механизм распределения Δ_{total} становится важным дополнительным этапом.

Перспективным направлением является создание нейронной сети, которая напрямую предсказывает посуточные приросты (дельты) в рамках одного прогноза. Такой подход позволяет моделировать детализированное распределение промо-эффекта без дополнительного шага «локального» или «гибридного» деления. Суть состоит в том, что нейросеть (например, многослойный персептрон — MLP) получает на вход несколько типов данных:

1. Базовый прогноз на n дней (набор чисел $b_1, b_2, \dots, b_n$), отражающий «обычные» продажи без учета промо.
2. Итоговый промо-эффект — общая добавка к продажам за весь промо-период.

3. Дополнительные факторы (день недели, праздники, механика промо, глубина скидки и т. д.), позволяющие учесть особенности конкретной акции и внешнюю среду.

На выходе сеть формирует n значений $\Delta_1, \Delta_2, \dots, \Delta_n$, каждое из которых интерпретируется как прирост продаж в соответствующий день акции.

При мультивыходной постановке задача «разбивки» общего эффекта решается нейросетью непосредственно в ходе обучения. Это может быть особенно полезно при наличии большого числа промо-кейсов в обучающей выборке. При этом, как отмечено в [1, 2], целесообразно использовать гибридные системы, сочетающие статистические модели, нейросети и экспертные правила.

Заключение

В статье представлен гибридный метод распределения дневного промо-эффекта, основанный на смешивании локальных прогнозов (predicted) и исторического профиля (p).

Основные выводы:

1. Гибридное распределение (смешивание с помощью α) дает меньшую итоговую ошибку (WAPE), чем каждый из методов в отдельности.
2. Метод легко интегрируется в корпоративные информационные системы, совместим с ML-подходами и обеспечивает гибкую настройку под разные типы акций.
3. В дальнейших исследованиях возможно развитие подхода путем обучения α на исторических данных (meta-learning), переход к почасовому распределению и более глубокой интеграции с нейронными сетями.

Таким образом, предложенный способ улучшает точность детального прогноза, что особенно важно для розничных компаний, стремящихся оптимизировать планирование запасов, работу персонала и прочие операционные процессы в период промо-акций.

ЛИТЕРАТУРА

1. Ткаченко В.В., Волков Е.О., Кужильный А.В. Информационная система оценки потребительского спроса и прогнозирования результатов рекламных кампаний и промоакций // Естественнo-гуманитарные исследования. 2024. № 4 (54). С. 247–253.
2. Черний В.Н. Машинное обучение и нейросети как основа современных инноваций // Развитие регионов как фактор укрепления единства и целостности государства: сб. ст. 2024. Т. 14. С. 194–200.
3. Сюндюкова Е.В. Прогнозирование розничного спроса с использованием нейронных сетей и макроэкономических переменных // Экономика и качество систем связи. 2025. Т. 1. № 35. С. 122–131.
4. Чеметева М.С., Зобова С.В. Метод прогнозирования продаж на основе модели алгоритма XGBOOST // Научный вектор: сб. науч. тр. Изд-во Ростовского гос. экономического ун-та (РИНХ), 2024. Т. 10. С. 378–380.

© Быстров Александр Игоревич (alexandr.jri.bystrov@yandex.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»