

С.М. Сарсимбаева^{1*}, Д.Г. Акаман¹

¹Актюбинский региональный университет имени К.Жубанова, г. Актобе, Казахстан

*e-mail: saulesarsi@gmail.com

ПРОГНОЗИРОВАНИЕ СПРОСА НА УСЛУГИ КОМПЬЮТЕРНОГО ЦЕНТРА МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Аннотация

В статье представлено прикладное исследование задачи краткосрочного прогнозирования ежедневного числа обращений в компьютерный сервисный центр. Для двухлетнего ряда за 2023–2024 годы были сформированы календарные, лаговые и метеорологические признаки, а также реализован гибридный ансамбль базовых моделей Ridge, ElasticNet, SVR, Случайный лес, XGBoost и LightGBM. Во избежание утечки информации использовались строгие временные сдвиги признаков, логарифмирование целевой переменной и схема TimeSeriesSplit с пятью разбиениями. Веса ансамбля подбирались как задача ограниченной оптимизации методами SLSQP, роевой оптимизации (PSO), дифференциальной эволюции (DE) и имитации отжига (SA). Устойчивый результат среди исследованных, получен на базовом наборе признаков: гибридный ансамбль с оптимизацией весов методом PSO достиг $RMSE = 2.0847$, $MAE = 1.5988$, $MAPE = 20.62\%$ и $R^2 = 0.6315$. Показано, что усложнение признакового пространства тригонометрическим кодированием времени и дополнительными производными признаками не улучшает генерализацию. По сравнению с лучшей одиночной моделью по MAPE (SVR, 21.29%) выигрыш ансамблевого метода составил всего 0.67 процентного пункта, но компактный ансамблевый метод дает наиболее устойчивые результаты и годен для практической применимости в задаче прогнозирования короткого шумного временного ряда, полученного в результате шумного операционного спроса, обремененного хаотическими факторами.

Ключевые слова: машинное обучение, прогнозирование спроса, ансамбли моделей, эвристическая оптимизация, временные ряды, сервисный центр.

С.М. Сарсимбаева¹, Д.Г. Акаман¹

¹Қ. Жұбанов атындағы Ақтөбе өңірлік университеті, Ақтөбе қ., Қазақстан

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІ АРҚЫЛЫ КОМПЬЮТЕРЛІК ОРТАЛЫҚТЫҢ ҚЫЗМЕТТЕРІНЕ СҰРАНЫСТЫ БОЛЖАУ

Аңдатпа

Мақалада компьютерлік қызмет көрсету орталығына күнделікті түсетін өтінімдер санын қысқа мерзімді болжау мәселесіне арналған қолданбалы зерттеу ұсынылған. 2023–2024 жылдарға арналған екі жылдық қатар үшін күнтізбелік, лагтық және метеорологиялық белгілер құрастырылып, сондай-ақ Ridge, ElasticNet, SVR, Кездейсоқ орман, XGBoost және LightGBM базалық модельдерінен тұратын гибриді ансамбль жүзеге асырылды. Ақпараттың құпиялылығын бұзбау мақсатында белгілердің қатаң уақыттық ығысулары, мақсатты айнымалыны логарифмдеу және бес бөлікке бөлінген TimeSeriesSplit схемасы қолданылды. Ансамбль салмақтары шектеулі оңтайландыру есебі ретінде SLSQP әдісімен, бөлшектер тобының оңтайландыруы (PSO), дифференциалдық эволюция (DE) және күйдіруді имитациялау (SA) әдістерімен таңдалды. Ең жақсы нәтиже базалық белгілер жиынтығында алынды: салмақтарды PSO әдісімен оңтайландырған гибриді ансамбль $RMSE = 2.0847$, $MAE = 1.5988$, $MAPE = 20.62\%$ және $R^2 = 0.6315$ көрсеткіштеріне қол жеткізді. MAPE бойынша ең жақсы дара модельмен (SVR, 21.29%) салыстырғанда ұтыс 0.67 пайыздық тармақты құрады. Уақытты тригонометриялық кодтау және қосымша туынды белгілер арқылы белгілер кеңістігін күрделендіру жалпылау сапасын арттырмайтыны көрсетілді. Алынған нәтижелер хаустық факторлармен күрделенген шулы операциялық сұранысты болжау үшін ықшам ансамбльдердің практикалық тұрғыдан қолдануға жарамдылығын растайды.

Түйін сөздер: машиналық оқыту, сұранысты болжау, модельдер ансамбльдері, эвристикалық оңтайландыру, уақыттық қатарлар, қызмет көрсету орталығы.

S.M. Sarsimbayeva¹, D.G. Akaman¹

¹K. Zhubanov Aktobe Regional University, Aktobe, Kazakhstan

FORECASTING DEMAND FOR COMPUTER CENTER SERVICES MACHINE LEARNING METHODS

Abstract

This paper presents an applied study of the problem of short-term forecasting of the daily number of requests to a computer service center. For a two-year time series covering 2023–2024, calendar, lag-based, and meteorological features were constructed, and a hybrid ensemble of base models – Ridge, ElasticNet, SVR, Random Forest, XGBoost, and LightGBM – was implemented. To prevent data leakage, strict temporal feature shifting, logarithmic transformation of the target variable, and a TimeSeriesSplit scheme with five splits were employed. Ensemble weights were optimized as a constrained optimization problem using SLSQP, Particle Swarm Optimization (PSO), Differential Evolution (DE), and Simulated Annealing (SA). The best performance was achieved on the baseline feature set: the hybrid ensemble with PSO-based weight optimization reached RMSE = 2.0847, MAE = 1.5988, MAPE = 20.62%, and $R^2 = 0.6315$. Compared to the best single model in terms of MAPE (SVR, 21.29%), the improvement amounted to 0.67 percentage points. It is shown that increasing feature space complexity through trigonometric time encoding and additional derived features does not improve generalization performance. The obtained results confirm the practical applicability of compact ensembles for forecasting noisy operational demand affected by chaotic factors.

Keywords: machine learning, demand forecasting, model ensembles, heuristic optimization, time series, service center.

Введение

Предсказание спроса на услуги сервисного обслуживания компьютерной техники принадлежит к числу сложных прикладных задач. В сравнении с розничными продажами здесь обычно наблюдаются более короткие временные ряды, да и слабее выраженная сезонность плюс более высокая доля случайных колебаний. На ежедневное количество обращений влияют такие признаки как: является ли день выходным, праздничным и каковы погодные условия. Также на это влияют и технические неполадки и специфика работы центра техобслуживания. Поэтому модели, успешно работающие при обычном прогнозировании спроса в рознице, часто неприменимы к этим данным с ухудшением качества [1, 2].

Работы в области центров поддержки вместе с центрами обработки вызовов, по сути близкое направление исследований. Спрос на запасные части также относится к нему. Эти публикации показывают нам, что в шумных операционных рядах преуспевают или компактные модели с тщательно подобранными лагами, или гибридные схемы, которые объединяют несколько алгоритмов разной природы из области [3-5]. Вместе с тем, вопрос касающийся того, каким способом лучше подбирать веса ансамбля, все еще остается открытым.

Практическая значимость решаемых задач в настоящее время высока. Вследствие ошибки прогноза происходит избыточная закупка комплектующих, а также неэффективное распределение загрузки мастеров. С другой стороны, это приводит к дефициту по запчастям, росту во времени ремонта и ухудшению в качестве клиентского сервиса. Для малых и средних сервисных фирм требуется решение, которое является достаточно простым для внедрения и точным в сопровождении [6, 7].

В большинстве прикладных работ отдельные модели сравниваются между собой без детального анализа в отношении того, каким образом меняется качество при ансамблировании, но также в отношении того, насколько устойчивы разные методы для оптимизации весов [8-9]. В нашей статье эта проблема рассматривается уже на основе подлинных данных сервисного центра. Сравниваются одиночные модели. Также гибридные ансамбли сравниваются с четырьмя способами настройки весов: SLSQP, PSO, DE и SA. В частности, влияние сложности признакового пространства оценивается на качество прогноза, поэтому влияние оценивается отдельно. Для оптимизации весов ансамбля были выбраны четыре метода, представляющие различные классы оптимизационных подходов: градиентный

метод SLSQP, роевой алгоритм PSO, популяционный алгоритм дифференциальной эволюции (DE) и стохастический метод имитации отжига (SA). Цель состояла не в исчерпывающем сравнении всех существующих алгоритмов оптимизации, а в анализе поведения различных классов методов на задаче прогнозирования короткого шумного временного ряда.

Цель исследования состоит в том, чтобы установить, какой набор признаков наряду с каким способом ансамблирования дают наилучший результат для краткосрочного прогнозирования числа обращений в компьютерный сервисный центр. Для этого было сформировано три отдельных экспериментальных этапа реализации, реализованы разнородные базовые модели посредством сопоставления, а также проведено сопоставление полученных метрик как между этапами, да и с близкими публикациями.

Методология исследования

Данные и методика исследования

Первоначальный набор данных был сформирован из записей об обращениях в сервисный центр в течение 2023, 2024 годов. После агрегации вплоть до суточного уровня целевой переменной, вышло ежедневное число заявок. Также по каждой дате были собраны погодные показатели совместно с календарными признаками, такими как признак выходного дня плюс индикатор праздника. Подобный формат подходит для реальной задачи оперативного планирования, в случае когда руководителю требуется оценить ожидаемую нагрузку на наступающий день.

Для того чтобы предотвратить утечку данных, все производные признаки строились, и строились только из той информации, что уже была доступна в момент прогноза. Лаги в 1 день, а также лаги в 7 дней рассчитывались на основе предыдущих наблюдений, скользящие средние использовали лишь сдвинутые значения целевой переменной, а температурные признаки включались тоже со сдвигом на один день. Благодаря этому подходу появилась возможность исключить заглядывание в будущее, а также обеспечить корректность для схемы валидации.

Эксперимент включал три этапа. На первом этапе применялся компактный набор признаков, включая день недели, выходной день и праздничный день. В набор входили также данные про среднюю температуру за предыдущий день, лаг 1 день, лаг 7 дней, скользящее среднее за 3 дня и скользящее среднее за 7 дней. На втором этапе день недели кодировался посредством синуса дня недели, а также посредством косинуса дня недели. Это давало возможность проверить на практике пользу от тригонометрического представления цикличности. На третьем этапе базовое пространство расширялось посредством признака изменения температуры. В дополнение ко всему этому, еще добавлялись скользящее стандартное отклонение за семь дней, а также признак самого конца месяца.

В виде базовых алгоритмов рассматривались Ridge, ElasticNet, SVR, Случайный лес, XGBoost в дереве решений, XGBoost в линейной форме и LightGBM. Этот набор объединяет модели, обладающие разным индуктивным смещением, начиная от устойчивых линейных схем и завершая более гибкими деревьями решений с опорными векторами. Линейная модификация была исследована только для XGBoost, поскольку библиотека предоставляет специальный режим `gblinear`. В библиотеке LightGBM аналогичный линейный режим отсутствует. Представление линейного семейства моделей в исследовании обеспечивалось также алгоритмами Ridge и ElasticNet. При обучении целевая переменная была преобразована логарифмически: $\ln(1 + y)$. Итоговые прогнозы затем возвращались в свой исходный масштаб посредством обратного преобразования. Оценка качества моделей выполнялась с `TimeSeriesSplit` при пяти разбиениях. В рамках каждой обучающей части выделялась отдельная валидационная выборка, на которой осуществлялся процесс для подбора весов гибридных ансамблей. Для оценивания применялись метрики RMSE, MAE, MAPE плюс коэффициент детерминации R^2 . Этот набор дает возможность оценить в среднем абсолютную

ошибку, а также чувствительность к крупным промахам. Оно позволяет оценить общую объясненную долю вариации.

Разведочный анализ данных

Вплоть до этапа моделирования был выполнен краткий разведочный анализ над суточным рядом обращений. Событийный журнал агрегировали по датам, поэтому получено 625 календарных наблюдений. В итоговую выборку вошли 618 наблюдений после построения лаговых и скользящих признаков. Суточный ряд характеризуется в целом умеренной вариативностью: среднее значение составляет около 10.34 обращения в день, медиана же равна 11, а диапазон в основном колеблется от 1 до 18 заявок.

Анализ спроса по дням недели демонстрирует, что пик нагрузки приходится на будни, а в субботу среднее количество запросов снижается почти в три раза. Это хорошо согласуется с высокой важностью календарных признаков в лучших моделях, а также объясняет, почему переменные день недели и выходной день оказываются столь значимыми для итогового ансамбля (Рисунок 1).




Рисунок 1. Суточный ряд обращений и средняя нагрузка по дням недели

Визуальный анализ подтверждает, что в ряде нет устойчивого линейного тренда, а доминирующей закономерностью выступает недельная повторяемость на фоне отдельных локальных всплесков (Рисунок 1). Именно по этой причине в работе нашли применение компактные лаговые признаки лаг 1 день, лаг 7 дней и скользящие средние, а не более тяжелые сезонные конструкции.

Настройка базовых моделей

Гиперпараметры базовых алгоритмов подбирались с консерватизмом: акцент делался не на агрессивном поиске предельно сложной конфигурации, а на устойчивости к переобучению и воспроизводимости результатов. Ограниченные глубины использовались для деревьев решений; умеренная регуляризация применялась к линейным моделям. Этот подход соответствует прикладной постановке задачи, где важны интерпретируемость, стабильность вместе с возможностью внедрения на стандартном стеке Python без дорогостоящей вычислительной инфраструктуры (Таблица 1). Количество этапов, схема экспериментальных этапов, а также наборы признаков показаны в Таблице 2.

Таблица 1. Основные гиперпараметры базовых моделей

Модель	Основные параметры
<i>Ridge</i>	$\alpha = 10.0$
<i>ElasticNet</i>	$\alpha = 0.1$; $l1 \text{ ratio} = 0.5$
<i>SVR</i>	$\text{kernel} = \text{linear}$; $C = 1.0$; $\text{epsilon} = 0.2$
Случайный лес	$n \text{ estimators} = 100$; $\text{max depth} = 5$
<i>XGBoost</i> (деревья)	$n \text{ estimators} = 100$; $\text{max depth} = 4$
<i>LightGBM</i>	$n \text{ estimators} = 100$; $\text{max depth} = 4$
<i>XGBoost</i> (линейный)	$\text{booster} = \text{gblinear}$; $\alpha = 0.1$

Таблица 2. Схема экспериментальных этапов и наборов признаков

Этап	Набор признаков	Базовые модели	Цель этапа
1	день недели, выходной день, праздничный день, средняя температура за предыдущий день, лаг 1 день, лаг 7 дней, скользящее среднее за 3 дня, скользящее среднее за 7 дней	<i>Ridge</i> , <i>ElasticNet</i> , <i>SVR</i> , <i>RF</i> , <i>XGBoost</i> , <i>LightGBM</i>	Оценить устойчивость базового без утечки данных набора признаков
2	синус дня недели, косинус дня недели, выходной день, праздничный день, средняя температура за предыдущий день, лаг 1 день, лаг 7 дней, скользящее среднее за 3 дня, скользящее среднее за 7 дней	<i>Ridge</i> , <i>ElasticNet</i> , <i>SVR</i> , <i>XGBoost</i> линейный	Проверить полезность тригонометрического кодирования времени
3	Этап 1 + признак изменения температуры, скользящее стандартное отклонение за 7 дней, признак конца месяца	<i>Ridge</i> , <i>ElasticNet</i> , <i>SVR</i> , <i>RF</i> , <i>XGBoost</i> , <i>LightGBM</i>	Проверить, дает ли расширенное конструирование признаков прирост качества

Результаты исследования

Результаты вычислительного эксперимента

Результаты базового этапа показывают, что даже среди одиночных моделей качество оказалось достаточно близким: *Ridge* и *SVR* продемонстрировали лучшие значения среди одиночных алгоритмов, тогда как деревья решений в рассматриваемой задаче чаще уступали им по точности. Это косвенно указывает на то, что при малом и шумном ряде чрезмерно гибкие алгоритмы легче подхватывают локальные колебания, чем устойчивый сигнал.

Гибридные ансамбли позволили дополнительно улучшить качество. Хороший результат на базовом этапе показал Гибрид (PSO), который улучшил все четыре основные метрики по сравнению с лучшей одиночной моделью. Выигрыш оказался не огромным, но устойчивым, что особенно важно для прикладной задачи: речь идет не о случайном скачке в одном разбиении, а о систематическом преимуществе ансамблирования (Таблица 3).

Таблица 3. Метрики моделей на базовом этапе

Модель	RMSE	MAE	MAPE, %	R^2	Комментарий
<i>Ridge</i>	2.1511	1.6648	21.87	0.6045	Сильная линейная база, устойчивое качество
Случайный лес	2.2526	1.7238	21.67	0.5688	Умеренно хуже линейных моделей
<i>XGBoost</i> (деревья)	2.4691	1.9454	23.69	0.4850	Склонность к переобучению на шумовых колебаниях

<i>LightGBM</i>	2.3887	1.9098	25.49	0.5071	Наиболее нестабильная модель на выборке
<i>ElasticNet</i>	2.2494	1.8008	25.14	0.5676	Регуляризация не дала самостоятельного выигрыша
<i>SVR</i>	2.1515	1.6554	21.29	0.6038	Лучшая одиночная модель по MAPE
<i>XGBoost (линейный)</i>	2.1773	1.6777	21.75	0.5919	Близок к Ridge и SVR
<i>Гибрид (SLSQP)</i>	2.1009	1.6105	20.74	0.6248	Улучшение за счет оптимизации весов
<i>Гибрид (PSO)</i>	2.0847	1.5988	20.62	0.6315	Лучший итоговый результат
<i>Гибрид (DE)</i>	2.1009	1.6105	20.74	0.6248	Практически совпал с SLSQP
<i>Гибрид (SA)</i>	2.1009	1.6105	20.74	0.6248	Практически совпал с SLSQP

Особого внимания заслуживает сравнение алгоритмов оптимизации весов. SLSQP, DE вместе с SA пришли почти к тому же качеству. PSO продемонстрировал небольшое практическое преимущество по метрикам RMSE, MAE, MAPE и R^2 , однако различия между методами оказались незначительными. Это означает, что в рассматриваемой задаче роевой поиск можно применять для настройки мета-ансамбля (Таблица 4).

Таблица 4. Сравнение методов оптимизации весов ансамбля на базовом этапе

Метод оптимизации	RMSE	MAE	MAPE, %	R^2	Комментарий
<i>SLSQP</i>	2.1009	1.6105	20.74	0.6248	Сильный математический базовый ориентир
<i>PSO</i>	2.0847	1.5988	20.62	0.6315	Небольшое практическое преимущество среди всех методов
<i>DE</i>	2.1009	1.6105	20.74	0.6248	Почти совпал с SLSQP
<i>SA</i>	2.1009	1.6105	20.74	0.6248	Почти совпал с SLSQP

Следует отметить, что различия между методами оптимизации весов ансамбля оказались небольшими. Разница между лучшим результатом PSO (RMSE = 2.0847) и результатами SLSQP, DE и SA (RMSE = 2.1009) составляет менее 0.8%. С учетом наблюдаемой вариативности между временными фолдами (Таблица 7) данное различие следует интерпретировать как практическое, а не как статистически доказанное превосходство одного метода над другим. Поэтому результаты свидетельствуют скорее о высокой устойчивости ансамблевого подхода к выбору конкретного алгоритма оптимизации весов.

Сравнение между тремя экспериментальными этапами подтверждает, что более сложное признаковое пространство не гарантирует улучшения. В противоположность этому, самый лучший результат был получен на первом, самом компактном этапе. Это важный итог работы: для данной прикладной задачи полезнее оказался вовсе не максимальный объем признаков, а база плюс интерпретируемый набор (Таблица 5).

Таблица 5. Сравнение трех экспериментальных этапов

Этап	Набор признаков	Лучшая модель этапа	RMSE	MAE	MAPE, %	R ²	Вывод
1	Базовые календарные, погодные и лаговые признаки	Гибрид (PSO)	2.0847	1.5988	20.62	0.6315	Лучший баланс между простотой и качеством
2	Синусно-косинусное кодирование дня недели + базовые лаги	Гибриды эквивалентны	2.1712	1.6624	21.92	0.5929	Усложнение временного кодирования не помогло
3	База + признак изменения температуры, скользящее стандартное отклонение за 7 дней, признак конца месяца	Гибрид (DE/SA)	2.1838	1.6920	21.55	0.5891	Дополнительные признаки не дали прироста генерализации

Интерпретация признаков

Для понимания причин превосходства базового этапа над сложными конфигурациями была проведена интерпретация признаков. Она была выполнена дополнительно на полном наборе данных базового этапа. Для этого применялась модель Ridge. Дополнительно для этого применялся ансамблевый метод Случайный лес. Различие механизмов обучения присутствует; обе модели согласованно выделяют календарный блок, а также сглаженные лаговые признаки как основные источники прогностического сигнала (Таблица 6).

Таблица 6. Наиболее значимые признаки базового этапа

Признак	Ridge / коэф.	Важность RF	Краткая интерпретация
Выходной день	0.330	0.571	Главный индикатор снижения нагрузки в субботу
День недели	0.045	0.283	Отражает внутринедельную структуру спроса
Скользящее среднее за 7 дней	0.075	0.063	Фиксирует локальный недельный уровень обращений
Средняя температура за предыдущий день	0.017	0.036	Добавляет внешний контекст, но не доминирует
Скользящее среднее за 3 дня	0.038	0.022	Сглаживает краткосрочные колебания

Важность признака выходной день в обеих моделях объясняется из-за резкого отличия субботней нагрузки от будних дней. Признаки скользящая средняя за семь дней и скользящая средняя за три дня, в свой черёд, помогают сглаживать локальные всплески и выделять текущий уровень загруженности. Метеорологический фактор средняя температура вчера влияет слабее: он служит внешним контекстом, но не вытесняет лаговую структуру ряда.

Анализ устойчивости по фолдам предоставляет добавочные сведения. Для четырех наиболее показательных моделей были сопоставлены стандартные отклонения для основных метрик. Вариативность низка, и поэтому модель стабильна. При этом она меньше зависит от особенностей фрагмента ряда (Таблица 7).

Таблица 7. Устойчивость ключевых моделей по пяти временным фолдам

Модель	σ RMSE	σ MAE	σ MAPE, n.p.	σR^2
Ridge	0.5129	0.4050	7.70	0.1552
SVR	0.5240	0.4384	7.68	0.1613
Случайный лес	0.4896	0.3802	6.63	0.1431
Гибрид (PSO)	0.4340	0.3445	6.49	0.1186

Как видно из Таблицы 7, Гибрид (PSO) обеспечивает лучшие средние значения RMSE, MAE, MAPE и R^2 , демонстрируя наименьший разброс по четырем метрикам. Это важно для прикладного внедрения: модель оказывается не просто точной в среднем, но более устойчивой к смене контрольного интервала. В области управления рисками это означает более предсказуемое качество прогноза. Это важно при планировании загрузки мастеров и закупок комплектующих.

Сопоставление с близкими научными публикациями

Для целей сопоставления были отобраны те публикации, что являются максимально близкими по постановке задачи, а именно: аналитика центров поддержки и центров обработки вызовов, прогнозирование прерывистого спроса на запасные части, спрос на техническое обслуживание, а также те работы, где применялись ансамбли и метаэвристики для настройки прогнозных схем. Такой отбор позволяет избежать некорректного сравнения с доменами. В этих доменах ряд заметно длиннее, регулярнее и проще для моделирования.

Нужно проявлять осторожность, и абсолютные значения MAPE следует интерпретировать между разными предметными областями. Потоки вызовов в центрах обработки вызовов, потоки поступлений в больничных системах, либо спрос в зданиях часто обладают более выраженной цикличностью, а также большим объемом данных, чем обращения в сервисный центр. Поэтому основная ценность сопоставления заключается не столько в простом сравнении чисел, но в том, чтобы понять, какие закономерности подтверждаются и в нашей задаче.

Почти что все близкие исследования приводят к одному и тому же выводу: разнородные ансамбли и аккуратный подбор признаков обычно оказываются эффективнее одиночной модели, а гибридные схемы особенно полезны там, где ряд шумный и содержит нерегулярные всплески. Наш результат хорошо вписывается в данную логику. В сравнении с другими публикациями по операционным процессам, полученная точность выглядит конкурентоспособной. Это особенно заметно с учетом малого объема данных, а также отсутствия тяжелой нейросетевой архитектуры (Таблица 8).

Таблица 8. Сопоставление настоящего исследования с близкими публикациями

Авторы, год	Предметная область и тип данных	Сравниваемые методы	Лучший подход	Основной результат
Nikseresht и др., 2024 [2]	Гарантийные обращения / спрос на послепродажный сервис	TVF-EMD, DE-RVFL, байесовская оптимизация, сигналы из социальных сетей	Гибрид TVF-EMD + DE-RVFL	RMSE снижен на 23.37–88.76% относительно базовых моделей; показана польза гибридных схем для сервисных обращений
Tartuk и др., 2022 [9]	Поток обращений в центр обработки вызовов, дневной уровень	XGBoost, скользящее среднее, подходы с учетом	XGBoost + предыдущие наблюдения/скользящее среднее	Средний MAE снижен на 15.59–28.01% по сравнению с базовыми схемами

		предыдущих наблюдений		
<i>Albrecht и др., 2021 [10]</i>	<i>Внутридневной поток обращений в центр обработки вызовов</i>	<i>RF, модели машинного обучения и модели временных рядов</i>	<i>Случайный лес</i>	<i>Показано преимущество методов машинного обучения над частью классических подходов в домене центров обработки вызовов</i>
<i>Falatouri и др., 2023 [11]</i>	<i>Спрос на техническое обслуживание бытовой техники</i>	<i>Пространственно-временная нейросеть и традиционные модели</i>	<i>Пространственно-временная сеть</i>	<i>MAPE улучшен более чем на 6% относительно лучшей традиционной модели</i>
<i>Zhang и др., 2022 [7]</i>	<i>Ежедневные поступления в отделение неотложной помощи</i>	<i>SVR, RF, Ridge, XGBoost, ARIMA</i>	<i>SVR</i>	<i>SVR достиг MAPE 8.81%; календарные и погодные признаки дали устойчивый эффект</i>
<i>Porto и Fogliatto, 2024 [12]</i>	<i>Ежедневные поступления в отделение неотложной помощи, 11 наборов данных</i>	<i>XGBoost, LightGBM, SVM-RBF, NNAR и др.</i>	<i>XGBoost</i>	<i>MAPE в диапазоне 5.03–14.1%; подтверждена польза конструирования признаков и методов машинного обучения на ежедневном сервисном потоке</i>
<i>Настоящее исследование</i>	<i>Услуги компьютерного сервисного центра, прерывистый краткосрочный спрос</i>	<i>Ridge, ElasticNet, SVR, RF, XGBoost, LightGBM, гибриды с SLSQP, PSO, DE и SA</i>	<i>Гибридный ансамбль с PSO</i>	<i>RMSE = 2.0847; MAE = 1.5988; MAPE = 20.62%; R² = 0.6315; выигрыш 0.67 п.п. к лучшей одиночной модели</i>

Практическая интерпретация и научные выводы

С практической стороны, полученный уровень точности делает предложенную модель годной для оперативного планирования. Сервисный центр получает достаточно надежную оценку дневной нагрузки при MAPE около 20.6%. Это позволяет заранее распределять работу инженеров, корректировать приемку техники и планировать минимальный запас наиболее востребованных комплектующих. Для небольших компаний как раз такой уровень управляемости часто оказывается важнее, нежели попытка получить еще несколько десятых процента посредством резко усложненной архитектуры.

Не менее важно и то, что наилучший результат достигнут при отсутствии тяжелых нейросетевых моделей. Это снижает порог для внедрения: решение можно реализовать на стандартном стеке языка Python, контролировать вклад от отдельных базовых моделей и при необходимости быстро переобучать ансамбль на обновленных данных. Для бизнеса этот метод кажется ясным и стабильным в использовании.

С научной точки зрения, работа приводит к нескольким основательным и устойчивым выводам. Во-первых, при условиях малого плюс шумного ряда компактный набор лаговых и погодных признаков без утечки данных оказывается полезнее, нежели более сложное конструирование признаков. Во-вторых, ансамблирование реально улучшает результат в сравнении с одиночными моделями, даже если прирост выражается менее чем на один процентный пункт по MAPE. В-третьих, PSO показал лучшие средние значения метрик среди исследованных методов оптимизации, достигнув RMSE = 2.0847, MAE = 1.5988, MAPE = 20.62% и R² = 0.6315 на базовом наборе признаков, однако статистически значимого превосходства над SLSQP, DE и SA не установлено.

Дискуссия

Особый интерес представляют гипотезы, которые не получили подтверждения. Во-первых, предполагалось, что тригонометрическое кодирование дня недели позволит лучше представить циклическую природу временного признака. Однако результаты второго этапа показали ухудшение качества относительно базового набора признаков. По анализу данных, использованных в ходе экспериментов можно констатировать, что тригонометрическое кодирование времени плюс добавление производных статистических признаков не улучшают генерализацию на имеющемся объеме данных. Это позволяет сделать такой практический вывод: для рассматриваемой задачи вполне оправдано использование компактной и хорошо интерпретируемой модели, а не максимально сложной схемы признаков. Вероятно, для короткого ряда с выраженным различием между будними днями и субботой простое категориальное представление оказалось более информативным.

Во-вторых, ожидалось, что расширение пространства признаков за счет производных погодных характеристик и статистик волатильности повысит качество прогноза. Однако на третьем этапе наблюдалось снижение генерализующей способности. Это может свидетельствовать о том, что дополнительные признаки в рассматриваемой задаче преимущественно увеличивали шумовую составляющую модели.

В-третьих, предполагалось, что эвристические методы оптимизации существенно превзойдут классический градиентный подход. Однако результаты показали практически одинаковые решения для SLSQP, DE и SA, что косвенно указывает на относительно простую структуру оптимизируемого пространства весов ансамбля.

Заключение

В исследовании выяснилось, что точный прогноз спроса на услуги центра возможен благодаря организации лагов и объединению разных моделей, а не из-за усложнения признаков. В конечном счете, гибридный ансамбль с оптимизацией весов методом PSO продемонстрировал небольшое практическое преимущество, при этом сочетая точность с устойчивостью среди проверенных алгоритмов оптимизации весов. Сравнение трех этапов эксперимента показало это.

Полученный результат сопоставляется с близкими публикациями. Это подтверждает, что он находится в рамках современного уровня исследований по прогнозированию в сервисных и операционных доменах. При этом ценность работы состоит в достигнутой точности и устойчивости найденного решения. Также ценность работы состоит в воспроизводимой схеме построения ансамбля для реального малого и шумного ряда обращений.

Ограничения исследования. В работе не рассматривались методы байесовской оптимизации, которые могут быть эффективны при малой размерности пространства параметров. Их сопоставление с исследованными алгоритмами представляет интересное направление дальнейших исследований.

Несмотря на достижение наилучших результатов ансамблем с оптимизацией PSO, абсолютный выигрыш относительно лучшей одиночной модели составил лишь 0.67 процентного пункта по MAPE. В условиях ограниченных вычислительных ресурсов или необходимости максимально простой эксплуатации использование одиночной модели SVR может оказаться более предпочтительным. Таким образом, выбор между ансамблем и одиночной моделью должен определяться балансом между требуемой точностью, вычислительной сложностью и затратами на сопровождение модели. Кроме того, исследование выполнено на данных одного сервисного центра и охватывает период продолжительностью два года. Поэтому переносимость результатов на другие сервисные организации требует дополнительной проверки.

Список использованных источников

- [1] Kiygi-Calli M., Weverbergh M., Franses P. H. *Forecasting time-varying arrivals: Impact of direct response advertising on call center performance* // *Journal of Business Research*. – 2021. – Vol. 131. – P. 227–240. – DOI: 10.1016/j.jbusres.2021.03.014.
- [2] Nikseresht A., Shokouhyar S., Babae Tirkolae E., Nikoogar E., Shokoohyar S. *An intelligent decision support system for warranty claims forecasting: Merits of social media and quality function deployment* // *Technological Forecasting and Social Change*. – 2024. – Vol. 201. – Art. 123268. – DOI: 10.1016/j.techfore.2024.123268.
- [3] Manno A., Rossi F., Smriglio S., Cerone L. *Comparing deep and shallow neural networks in forecasting call center arrivals* // *Soft Computing*. – 2023. – Vol. 27. – P. 12943–12957. – DOI: 10.1007/s00500-022-07055-2.
- [4] Pinçe Ç., Turrini L., Meissner J. *Intermittent demand forecasting for spare parts: a critical review* // *Omega*. – 2021. – Vol. 105. – Art. 102513. – DOI: 10.1016/j.omega.2021.102513.
- [5] Chacon H., Koppiseti V., Hardage D., Choo K.-K. R., Rad P. *Forecasting call center arrivals using temporal memory networks and gradient boosting algorithm* // *Expert Systems with Applications*. – 2023. – Vol. 224. – Art. 119983. – DOI: 10.1016/j.eswa.2023.119983.
- [6] Pekel E., Gul M., Celik E., Yousefi S. *Metaheuristic approaches integrated with ANN in forecasting daily emergency department visits* // *Mathematics*. – 2021. – Vol. 9, no. 18. – Art. 2281. – DOI: 10.3390/math9182281.
- [7] Zhang Y., Zhang J., Tao M., Shu J., Zhu D. *Forecasting patient arrivals at emergency department using calendar and meteorological information* // *Applied Intelligence*. – 2022. – Vol. 52. – P. 11232–11243. – DOI: 10.1007/s10489-021-03085-9.
- [8] Tuominen J., Lomio F., Oksala N., Palomäki A., Peltonen J., Huttunen H., Roine A. *Forecasting daily emergency department arrivals using high-dimensional data and ensemble methods* // *BMC Medical Informatics and Decision Making*. – 2022. – Vol. 22. – Art. 105. – DOI: 10.1186/s12911-022-01878-7.
- [9] Tartuk M., Nurdağ T. F., Acar V., Erdem S., Akay F., Abut F. *Forecasting call center arrivals using XGBoost combined with consecutive and periodic moving averages* // *Applied Sciences*. – 2022. – Vol. 12, no. 20. – Art. 10369. – DOI: 10.3390/app122010369.
- [10] Albrecht T., Rausch T. M., Derra N. D. *Call me maybe: methods and practical implementation of artificial intelligence in call center arrivals' forecasting* // *Journal of Business Research*. – 2021. – Vol. 123. – P. 267–278. – DOI: 10.1016/j.jbusres.2020.09.033.
- [11] Falatouri T., Brandtner P., Nasser M., Darbanian F. *Maintenance forecasting model for geographically distributed home appliances using spatial-temporal neural networks* // *Computers & Industrial Engineering*. – 2023. – Vol. 176. – Art. 108936. – DOI: 10.1016/j.cie.2023.108936.
- [12] Porto B. M., Fogliatto F. S. *Enhanced forecasting of emergency department patient arrivals using feature engineering approach and machine learning* // *BMC Medical Informatics and Decision Making*. – 2024. – Vol. 24. – Art. 377. – DOI: 10.1186/s12911-024-02788-6.