

МАТЕМАТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

УДК 004.08

JEL C53

ФОРМИРОВАНИЕ СТРАТЕГИЧЕСКИХ И ТАКТИЧЕСКИХ ПРОГНОЗОВ НАГРУЗКИ КОНТАКТНОГО ЦЕНТРА

Азарнова Татьяна Васильевна¹, д-р тех. наук, проф.

Аснина Наталия Георгиевна², канд. тех. наук, доц.

Маркова Виктория Алексеевна¹, маг.

¹ Воронежский государственный университет, Университетская пл., 1, Воронеж, Россия, 394018; e-mail: terlyuga@mail.ru

² Воронежский государственный технический университет, ул. 20-летия Октября, 84, Воронеж, Россия, 394006; e-mail: andrey050569@yandex.ru

Предмет: деятельность контактных центров становится неотъемлемой частью современного бизнеса. Контактные центры обеспечивают широкие возможности предоставления услуг и работы с клиентами. Эффективность работы данных структурных подразделений зависит от организации во времени и пространстве обслуживания поступающих звонков. *Цель:* разработать и обосновать базирующийся на методах статистического анализа данных и машинного обучения подход исследования ретроспективных данных по нагрузке контактного центра и формирования стратегических и тактических прогнозов интенсивности его работы. *Дизайн исследования:* контактный центр можно рассматривать как систему массового обслуживания (СМО). Формирование стратегических и тактических прогнозов нагрузки контактного центра позволит оценить интенсивность потока заявок, интенсивность процесса обслуживания и рассчитать основные характеристики эффективности функционирования контактного центра как системы массового обслуживания: среднее время обслуживания, среднее количество требований в очереди, среднее время пребывания заявки в очереди и другие характеристики СМО. Для анализа ретроспективных данных в работе используется целый спектр методов статистического анализа данных и машинного обучения: сезонная декомпозиция, Linear Regression, XGBoost, ARIMA, SVR. Для построения качественных прогнозов необходимо учесть особенности данных, связанные с разной загруженностью контактного центра в разный период времени в течение суток, разным трафиком в разные дни недели, наличием

праздников и рекламных акций. *Результаты:* создано специальное программное обеспечение. Совокупность используемых методов обработки данных позволила получить достаточно качественные прогнозы.

Ключевые слова: теория массового обслуживания, машинное обучение, сезонная декомпозиция, Linear Regression, XGBoost, ARIMA, SVR.

DOI: 10.17308/meps/2078-9017/2022/10/8-23

Введение

С развитием технологий увеличивается число каналов, по которым происходит взаимодействие компаний с клиентами. Помимо традиционной телефонии, сегодня используют электронную почту, веб-форму на сайте, мессенджеры, чат-боты и т. д. На смену call-центрам, для которых характерно общение с клиентом только посредством телефона, приходят контактные центры.

Под контактными центром понимают подразделение организации, целью которого является обработка поступающих обращений экстренного, консультативного, справочно-информационного, заказного или технического характера по различным каналам связи. В состав контактного центра входят сотрудники, которые отвечают на вызовы (операторы или агенты), менеджеры, которые руководят работой агентов, и различные функциональные системы (сервер голосовой почты, отображение на терминалах агентов информации о вызовах и клиенте и пр.).

Важной задачей управляющего контактными центром является планирование оптимального количества персонала. Поступление звонков носит случайный характер, это может приводить как к недогруженности, так и перегруженности операторов. Чтобы избежать подобных ситуаций, необходимо правильно предсказывать количество звонков, которые поступят в контактный центр в тот или иной момент времени и среднее время обслуживания одного звонка.

В данной сфере работает достаточно много аналитиков. Классическим аппаратом проведения подобных исследований является статистический анализ данных. Особенностью сферы исследования проблемы обслуживания звонков в контактных центрах является большой объем данных, даже в течение суток накапливаются целые массивы данных. Это открывает дополнительные возможности для применения современных технологий обработки больших данных и инструментов машинного обучения.

В работе [8] рассматривается модель подсчета прибытия, основанная на подходе смешанного процесса Пуассона. Модель применяется к данным колл-центра израильской телекоммуникационной компании. В модели учитывается влияние таких событий, как выставление счетов на процесс прибытия и демонстрируется, как включить этот параметр в модель в качестве экзогенных переменных. После получения прогнозируемой загрузки систе-

мы в крупных колл-центрах менеджер может выбрать применение правила режима QED (Quality-Efficiency Driven) подбора персонала, чтобы сбалансировать предлагаемую нагрузку на сервер с качеством обслуживания. Реализация этого правила укомплектования штатов требует, чтобы прогнозируемые значения числа прибытий и среднего времени обслуживания сохраняли определенный уровень точности. Авторы разработали различные критерии согласия, которые помогают определить практическую эффективность модели. Они показывают, что в течение большей части дня модель может достигать желаемого уровня точности.

В диссертации [12] анализируется прогнозирование нагрузки вызовов call-центра с помощью методов машинного обучения. Исследование направлено на то, чтобы выделить некоторые доминирующие аспекты поведения двух известных моделей машинного обучения и сравнить их возможности с моделью ARIMA. Рассматривается прогнозирование нагрузки в дневном и часовом масштабе. Данные характеризуются сезонностью как в дневном, так и часовом масштабе. Сравняются результаты моделирования сезонной искусственной нейронной сетью (ИНС) и LSTM с сезонной авторегрессионной моделью интегрированного скользящего среднего (SARIMA), которая является одним из наиболее распространенных статистических методов, используемых call-центрами. Основными показателями, используемыми для оценки результатов, являются нормализованная среднеквадратическая ошибка (NMSE) и средняя абсолютная ошибка в процентах (SMAPE). Проведены эксперименты с тремя различными наборами данных, предоставленными Teleopti. Экспериментальные результаты доказали, что SARIMA имеет более высокую точность прогнозирования в ежедневном масштабе по трем наборам данных. В часовом масштабе Seasonal ANN и LSTM превосходят SARIMA, демонстрируя надежность при горизонте прогнозирования в 160 пунктов. SARIMA не показывает корреляции между качеством модели и количеством данных, в то время как и SANN, и LSTM улучшаются вместе с возрастанием количества данных.

В работе [10] рассматриваются методы внутрисуточного и динамического внутрисуточного прогнозирования объемов входящих вызовов. Подход заключается в том, чтобы рассматривать профили внутрисуточных объемов вызовов как многомерные векторные временные ряды. Сначала уменьшается размерность путем сингулярной декомпозиции матрицы внутрисуточных профилей, а затем применяются методы временных рядов и регрессии. Метод учитывает как ежедневную динамику, так и внутрисуточную модель поступления звонков. Разрабатываются распределительные подходы для динамического прогнозирования в реальном времени.

В рамках данной работы рассматривается целый комплекс методов машинного обучения и статистического анализа данных [4,5] для формирования стратегических и тактических прогнозов нагрузки контактного центра. По предложенным алгоритмам разработано программное обеспечение

на языке программирования Python, которое позволило провести полномасштабный вычислительный эксперимент.

Методы и результаты исследования

Постановка задачи

Ежедневно в контактных центрах возникает множество оперативных задач, одной из которых является определение оптимального уровня укомплектования персоналом для обеспечения удовлетворенности клиентов и их потребностей при минимальных затратах на обслуживание. Для корректного составления расписания необходимо построение стратегического и тактического прогнозов будущей загрузки системы.

В рамках исследования рассматривается задача формирования стратегического (на уровне дня) и тактического (на уровне 15-минутных интервалов) прогнозов нагрузки контактного центра, который обрабатывает контакты по телефону в единой очереди. Данная задача предполагает получение:

- стратегического прогноза количества вызовов на каждый день на период с 01.09.2018 по 31.05.2019 года;
- тактического прогноза количества вызовов и среднего времени обработки контакта на каждый интервал (15 минут) на период с 01.03.2019 по 31.05.2019 года.

Исследование базируется на:

- интервальных ретроспективных данных по нагрузке контактного центра за три года – с 01.09.2015 по 31.08.2018 года;
- информации о событиях (день события и параметры события), в результате которых нагрузка отклонялась от типичной за период исторических данных;
- информацией о будущих событиях, в результате которых нагрузка будет отклоняться от типичной – на период прогнозирования.

Предполагается что: направление и динамика скорости изменения тенденции, которая сформировалась на ретроспективных данных, на периоде прогнозирования сохранятся; сезонные (внутригодовые, внутримесячные, внутринедельные и внутридневные) колебания нагрузки, сформировавшиеся на ретроспективных данных, значительно не изменятся.

Компания периодически проводит маркетинговые акции двух типов – реклама и рассылка. Предполагается, что эти события влияют на нагрузку только в день их проведения. Влияние рекламы и рассылки может зависеть от величины охвата аудитории.

Фрагменты ретроспективных данных и прошлых спецсобытий представлены на рисунках 1 и 2 соответственно.

ДАТА И ВРЕМЯ	КОЛИЧЕСТВО ПОСТУПИВШИХ ЗВОНКОВ	Среднее время обработки звонка
01.09.2015 0:00	59	307
01.09.2015 0:15	72	367
01.09.2015 0:30	49	335
01.09.2015 0:45	40	354
01.09.2015 1:00	29	327
01.09.2015 1:15	23	319
01.09.2015 1:30	43	328
01.09.2015 1:45	30	323
01.09.2015 2:00	14	286
01.09.2015 2:15	8	266
01.09.2015 2:30	11	287
01.09.2015 2:45	12	310
01.09.2015 3:00	10	293
01.09.2015 3:15	6	289

Рис. 1. Фрагмент ретроспективных данных

Дата	СОБЫТИЕ	Охват рассылки/рекламы
06.09.2015	РАССЫЛКА	1 187 000
05.10.2015	РЕКЛАМА	2 884 000
04.11.2015	ПРАЗДНИК	
10.11.2015	РАССЫЛКА	1 958 000
09.12.2015	РЕКЛАМА	1 361 000
20.12.2015	РАССЫЛКА	2 550 000
01.01.2016	ПРАЗДНИК	
02.01.2016	ПРАЗДНИК	
04.01.2016	ПРАЗДНИК	
05.01.2016	ПРАЗДНИК	
06.01.2016	ПРАЗДНИК	
07.01.2016	ПРАЗДНИК	
08.01.2016	ПРАЗДНИК	
14.01.2016	РАССЫЛКА	2 364 000
12.02.2016	РЕКЛАМА	1 322 000

Рис. 2. Фрагмент данных о прошлых спецсобытиях

Вычислительный эксперимент

Процедуры построения моделей машинного обучения, как правило, начинаются с предобработки исходных данных. Предобработка данных может включать в себя нормализацию, обрезку, заполнение пропусков и т. д.

Вначале продемонстрируем графики динамики количества поступивших звонков в разрезе дней (рис. 3).




Рис. 3. График динамики количества поступивших звонков

Визуальный анализ данных показывает, что целевые переменные содержат выбросы, а также аномальную частоту в последние три месяца. Предполагается, что причиной таких изменений является активная маркетинговая деятельность предприятия. Рассмотрим график проведения компанией спецсобытий (рис. 4).




Рис. 4. График спецсобытий

График спецсобытий подтверждает предположение об активности маркетинговой деятельности предприятия. Поэтому удалим последние аномальные значения из выборки. Для устранения выбросов воспользуемся методом замены медианным значением. Подобный способ преобразования данных целесообразен для авторегрессионных моделей прогнозирования, при реализации которых прогнозирование будущих значений ряда основано на значениях в прошлом.

Проанализировав работу контактного центра, можно установить, что характер колебаний объема вызовов является неравномерным. Предполагается, что в выходные дни звонков в контактный центр поступает меньше, чем в будние дни. В течение суток люди больше звонят в дневное время, чем в ночное. А в разрезе месяцев нагрузка на контактный центр в декабре значительно выше в сравнении с январем. Для построения стратегического прогноза был сформирован новый набор данных с бинарными предикторами дней недели, месяцев.

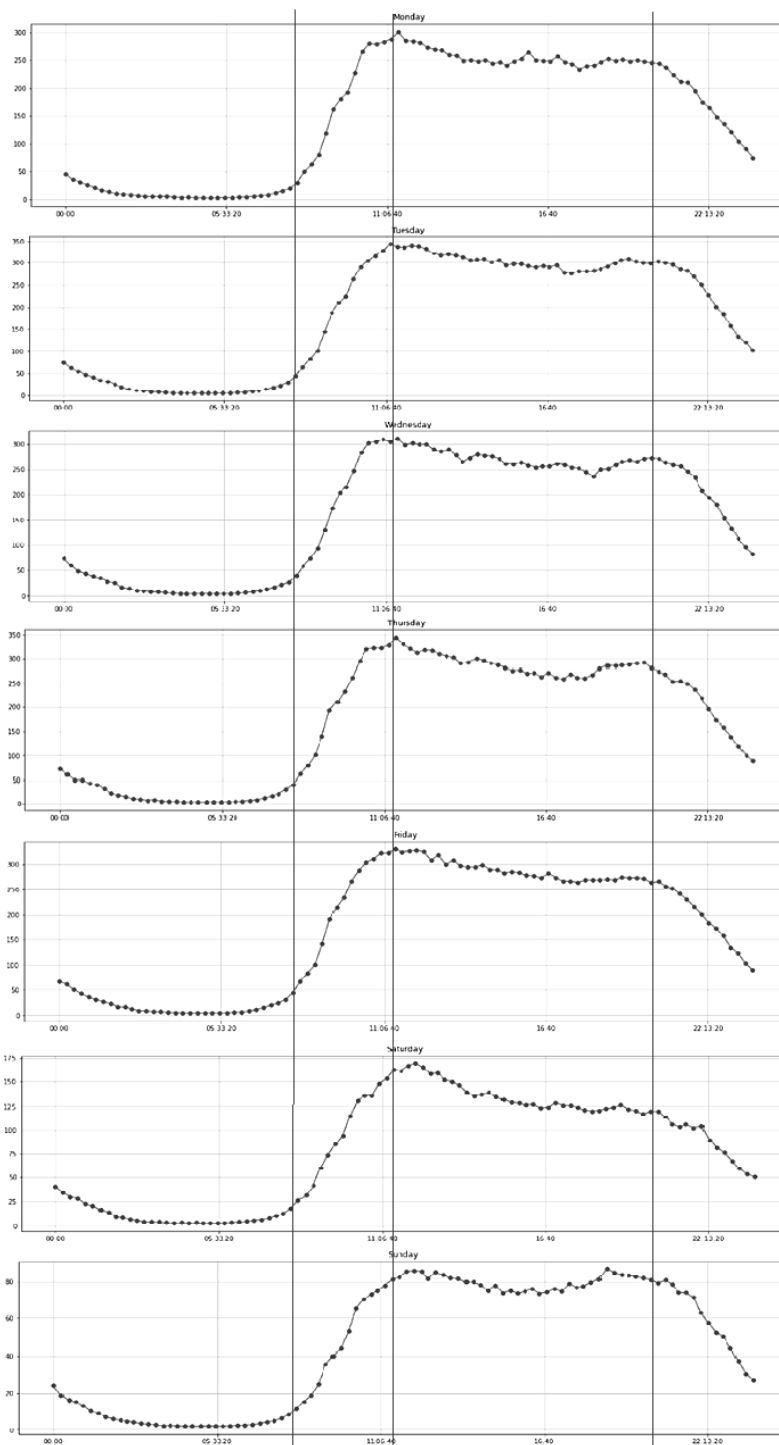


Рис. 5. Профили дней

Контактные центры имеют градацию активности звонков в течение суток: низкая активность, рост, высокая активность, час пик, спад. В каждый из этих периодов отклонение значений количества звонков от среднего

будет незначительным. Поэтому можно сгруппировать пятнадцатиминутные интервалы в периоды активности. Для того чтобы корректно определить временные границы таких периодов, необходимо проанализировать распределение звонков в течение суток (рис. 5).

Анализ показывает, что данные можно сгруппировать по четырем периодам:

- 1) низкая активность – данные с 00:00 до 08:00;
- 2) ост – данные с 08:00 до 11:00;
- 3) высокая активность – данные с 11:00 до 20:00;
- 4) спад – данные с 20:00 до 00:00.

На основе профилей дней создаем наборы данных в разрезе активности звонков, количество лаговых предикторов является произведением количества периодов и количества дней в недели ($4 \cdot 7 = 28$):

– наборы данных со сглаженным рядом для авторегрессионных моделей прогнозирования в разрезе дней и пятнадцатиминутных интервалов («flattened_dataset_day» и «flattened_dataset_period» соответственно);

– наборы данных с бинарными факторами по дням, неделям в разрезе дней и пятнадцатиминутных интервалов («dataset_day» и «dataset_period» соответственно);

– наборы данных с лаговыми факторами в разрезе дней и пятнадцатиминутных интервалов («dataset_day_lag» и «dataset_period_lag» соответственно);

– набор данных с лаговыми факторами по периодам активности («dataset_activity_period»).

Вначале проводим дисперсионный анализ [6] различия средних значений количества звонков по дням и интервалам (рис. 6).

	Проверка гипотезы о разнице средних значений количества звонков по дням	Проверка гипотезы о разнице средних значений количества звонков в разрезе временных интервалов	Проверка гипотезы о разнице средних значений количества звонков по периодам активности
Средние значения количества звонков	Monday: 14373 Tuesday: 17582 Wednesday: 15704 Thursday: 16613 Friday: 16459 Saturday: 7708 Sunday: 4508	00:00:00: 45 00:15:00: 35 00:30:00: 31 23:15:00: 104 23:30:00: 90 23:45:00: 74	0: 835 1: 1745 2: 8408 3: 2301
Величина статистики и p-value	H-statistic: 253.578 P-Value: 0.009856	H-statistic: 540.537 P-Value: 0.01615	H-statistic: 1083.48 P-Value: 0.047

Рис. 6. Дисперсионный анализ различия средних

Полученные значения p-value меньше порогового значения. Поэтому гипотезы H_0 отклоняются в пользу альтернативных гипотез о наличии существенной разницы средних. Таким образом, дисперсионный анализ подтвердил корректность выделенных предикторов.

Для прогнозирования будем использовать модели Linear Regression, XGBoost, ARIMA и SVR [5, 9, 11]. Оценку качества моделей будем проводить на основе средней абсолютной ошибки (MAE).

Для реализации ARIMA (p, d, q) необходимо проверить стационарность ряда. Проведем тест Дики-Фуллера. На рисунке 7 представлены результаты теста.

Показатель	flattened_dataset_day	flattened_dataset_period
Количество поступивших звонков	ADF Statistic: 4.4713580838 n_lags: 0.000221449119439 p-value: 0.00022144911943 Critical Values: 1%, - 3.436459 Critical Values: 5%, - 2.864237 Critical Values: 10%, - 2.56820	ADF Statistic: 24.0478610035314 n_lags: 0.0 p-value: 0.0 Critical Values: 1%, - 3.4304154398 Critical Values: 5%, -2.86156892 Critical Values: 10%, -2.56678539
Среднее время обработки звонка		ADF Statistic: - 21.1876347247845 n_lags: 0.0 p-value: 0.0 Critical Values: 1%, -3.431006659 Critical Values: 5%, - 2.8618302043 Critical Values: 10%, - 2.566924470

Рис. 7. Тест Дики-Фуллера

Значения параметра p-value близко к нулю, что подтверждает стационарность. Для определения параметров p, d, q строятся автокорреляционная и частная автокорреляционные функции для количества поступивших звонков по дням (рис. 8-10).




Рис. 8. ACF и PACF количества звонков по дням




Рис. 9. ACF и PACF количества звонков в разрезе пятнадцатиминутных интервалов

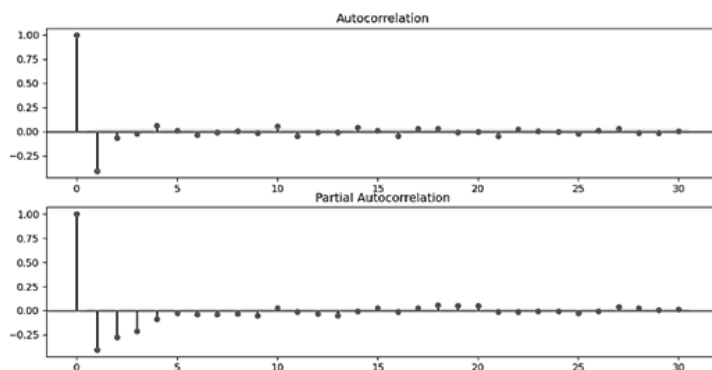


Рис. 10. ACF и PACF среднего времени обработки звонка

Таким образом, получили три модели: ARIMA(6, 0, 7) для прогнозирования количества поступивших звонков по дням, ARIMA(4, 0, 0) для прогнозирования количества поступивших звонков в разрезе временных интервалов и ARIMA(4, 0, 0) для прогнозирования среднего времени обработки звонка. Результаты представлены в таблице 1.

Таблица 1

MAE для прогнозных результатов методом ARIMA

	flattened dataset day	flattened dataset period
Количество полученных звонков	2635	115
Среднее время обработки звонка	22	27

Получены удовлетворительные результаты, недостатком применения такой модели является игнорирование влияния внешних факторов, которые выделены в исследуемых данных.

Воспользуемся методами простой линейной регрессии и XGBoost. Для последнего стандартизируем данные с помощью функции StandardScaler, так как модель чувствительна к масштабу данных и с помощью поиска по сетке (GridSearchCV) вычислим лучшие гиперпараметры.

После обучения модели на разных наборах данных получили следующие результаты, выраженные MAE (табл. 2 для линейной регрессии и табл. 3 для XGBoost).

Таблица 2

MAE для метода LR

	dataset day	dataset day lag	dataset period	dataset period lag	dataset activity period
Кол-во полученных звонков	2998	2073	82	14	1388
Ср. время обработки звонка	11	10	22	20	12

Таблица 3

MAE для метода XGBoost

	dataset day	dataset day lag	dataset period	dataset period lag	dataset activity period
Кол-во полученных звонков	2347	1315	29	11	509
Ср. время обработки звонка	4	4	12	11	4

Проанализировав таблицы, можно сделать вывод о том, что модель XGBoost дает более хорошие результаты. Продемонстрируем прогнозные значения с минимальной ошибкой (рис. 11).




Рис. 11. Графики прогнозных значений количества звонков и среднего времени обработки звонка

Для альтернативного моделирования воспользуемся методом опорных векторов для задач регрессии. Для построения адекватной модели необходимо нормализовать факторы и определить гиперпараметры модели. Для исследуемых данных оптимальными гиперпараметрами являются: $\text{kernel}='linear'$, $C=50.0$. Далее обучим модель и посчитаем MAE. Результаты представлены в таблице 4.

Таблица 4

MAE прогнозирования методом SVR

	dataset day	dataset day lag	dataset period	dataset period lag	dataset activity period
Кол-во полученных звонков	2228	1747	42	23	1648
Ср. время обработки звонка	6	4	10	8	14

На основе полученных результатов можно сделать следующие выводы:

- лаговые факторы оказывают более существенное влияние на результирующие показатели прогноза, нежели бинарные факторы дней недели;
- если в компании наблюдаются периоды активности звонков, то прогноз можно строить по сгруппированным данным;
- метод ARIMA требует выполнения определенных предположений,

что усложняет предобработку данных и вызывает необходимость проверки дополнительных гипотез, кроме того, модель не позволяет учитывать дополнительные внешние факторы;

– метод SVR показал достаточно высокие результаты и лучший показатель по производительности среди примененных методов;

– лучшие результаты по прогнозированию нагрузки контактного центра продемонстрировал алгоритм XGBoost.

Заключение

Контактные центры являются важными системами массового обслуживания в современном бизнесе. Эффективность их работы во многом определяется правильным планированием работы персонала, не допускающим низкую производительность и критическое пребывание заявок в очереди. Несмотря на широкий спектр исследований в области прогнозирования нагрузки контактных центров, актуальным является направление, связанное с разработкой современных инструментов прогнозирования, способных адаптироваться на специфику целевых показателей прогнозирования и структуру информации. Проведенные в работе эксперименты показывают, что комплексное использование методов машинного обучения совместно с методами статистического анализа данных позволяет строить инструменты прогнозирования, демонстрирующие достаточно высокую точность.

Список источников

1. Белозерчик А.С. Методы анализа данных в практических задачах исследования удовлетворенности клиентов качеством обслуживания при голосовых обращениях в контактные центры // *Альманах научных работ молодых ученых Университета ИТМО: XLVII научная и учебно-методическая конференция Университета ИТМО*, Санкт-Петербург, 31 января – 03 2018 года. Санкт-Петербург, ФГАОУ «Национальный исследовательский университет ИТМО», 2018, с. 165-167.

2. Душин В.М. Актуальные проблемы автоматизированных информационных систем прогнозирования нагрузки и планирования ресурсов в контактном центре // *Устойчивое развитие науки и образования*, 2021, no. 5(56), с. 41-45.

3. Еськов В.А., Солодухин К.С. Нечеткая модель расчета численности персонала контактного центра. Территория новых возможностей // *Вестник Владивостокского государственного университета экономики и сервиса*, 2022, т. 14, no. 3(56), с. 158-167.

4. Кизбикенов К.О. *Прогнозирование и*

временные ряды: учебное пособие для вузов. Барнаул, АлтГПУ, 2017. 115 с.

5. Овакимян А.С., Саркисян С.Г. Нейросетевое прогнозирование временных рядов // *Вестник Ереванского государственного университета*, 2013, no. 5, с. 16-22.

6. Унгурияну Т.Н. Сравнение трех и более независимых групп с использованием непараметрического критерия Краскела Уоллиса в программе STATA // *Экология человека*, 2014, no. 6, с. 55-58.

7. Фадеев С.Н., Брейдер Н.А. Оценка эффективности разделения каналов в системе массового обслуживания с неограниченной очередью // *Известия высших учебных заведений. Приборостроение*, 2021, т. 64, no. 5, с. 351-356.

8. Aldor-Noiman S., Feigin P., Mandelbaum A. Workload forecasting for a call center: Methodology and a case study // *The Annals of Applied Statistics*. 2010, vol. 3 (4), pp. 1403-1447.

9. Chih-Chung Chang, Chih-Jen Lin. *LIBSVM: A Library for Support Vector Machines*. *ACM Transactions on Intelligent Systems and Technology* (Taipei, 29 ноя-

бря 2019 г.). Taiwan, National Taiwan University, 2019, pp. 1-24.

10. Haipeng Shen, Jianhua Z. Huang. Interday Forecasting and Intraday Updating of Call Center Arrivals // *Manufacturing & Service Operations Management*, 2008, no. 10(3), pp. 391-410.

11. Ming-Chi Tsai [и др.]. Forecasting leading industry stock prices based on a hybrid time-series forecast model // *PLoS*

ONE (Alessandro Spelta, Italy, 31 декабря 2018 г.). Italy, Universita Cattolica del Sacro Cuore, 2018, pp. 1-24.

12. Nicola Baldon. Time series Forecast of Call volume in Call Centre using Statistical and Machine Learning Methods // *Degree project in computer science and engineering, second cycle, 30 credits Stockholm*. Sweden, 2019.

FORMATION OF STRATEGIC AND TACTICAL FORECASTS OF THE LOAD OF THE CONTACT CENTER

Azarnova Tatyana Vasilievna¹, Dr. Sci. (Eng.), Prof.

Asnina Natalia Georgievna², Cand. Sci. (Eng.), Assoc. Prof.

Markova Victoria Alexeyevna¹, M. Sc.

¹ Voronezh State University, University sq., 1, Voronezh, Russia, 394018; e-mail: terlyuga@mail.ru

² Voronezh State Technical University, 20th Anniversary of October st., 84, Voronezh, Russia, 394006; e-mail: andrey050569@yandex.ru

Importance: the activity of contact centers is becoming an integral part of modern business. Contact centers provide ample opportunities for providing services and working with clients. The efficiency of these structural divisions depends on the organization in time and space of servicing incoming calls. *Purpose:* to develop and justify an approach based on the methods of statistical data analysis and machine learning for studying historical data on the load of the contact center and forming strategic and tactical forecasts of the intensity of its work. *Research design:* the contact center can be viewed as a queuing system (QS). The formation of strategic and tactical forecasts of the load of the contact center will allow you to assess the intensity of the flow of applications, the intensity of the service process and calculate the main characteristics of the effectiveness of the functioning of the contact center as a queuing system: the average service time, the average number of requests in the queue, the average time the application stays in the queue and other QS characteristics. To analyze retrospective data, the work uses a whole range of statistical data analysis and machine learning methods: seasonal decomposition, Linear Regression, XGBoost, ARIMA, SVR. To build high-quality forecasts, it is necessary to take into account the data features associated with different workloads of the contact center at different times during the day, different traffic on different days of the week, the presence of holidays and promotions. *Results:* special software was created.

Keywords: queuing theory, machine learning, seasonal decomposition, Linear Regression, XGBoost, ARIMA, SVR.

References

1. Belozerchik A.S. Methods of data analysis in practical problems of studying customer satisfaction with the quality of service in voice calls to contact centers. *Almanac of scientific works of young scientists of ITMO University: XLVII scientific and educational conference of ITMO University*, St. Petersburg, January

- 31-03, 2018. St. Petersburg, FGAOU «National Research University ITMO», 2018, pp. 165-167. (In Russ.)
2. Dushin V.M. Actual problems of automated information systems for load forecasting and resource planning in the contact center. *Sustainable development of science and education*, 2021, no. 5(56), pp. 41-45. (In Russ.)
3. Eskov V.A., Solodukhin K.S. Fuzzy model for calculating the number of contact center personnel. The territory of new opportunities. *Bulletin of the Vladivostok State University of Economics and Service*, 2022, t. 14, no. 3(56), pp. 158-167. (In Russ.)
4. Kizbikenov K. O. *Forecasting and time series: textbook for universities*. Barnaul, AltSPU, 2017. 115 p. (In Russ.)
5. Ovakimyan A.S., Sarkisyan S.G. Neural network forecasting of time series. *Bulletin of Yerevan State University*, 2013, no. 5, pp. 16-22. (In Russ.)
6. Ungureanu T.N. Comparison of three or more independent groups using the nonparametric Kruskal Wallis test in the STATA program. *Human ecology*, 2014, no. 6, pp. 55-58. (In Russ.)
7. Fadeev S.N., Brader N.A. Evaluation of the efficiency of channel separation in a queuing system with an unlimited queue. *News of higher educational institutions. Instrumentation*, 2021, vol. 64, no. 5, pp. 351-356. (In Russ.)
8. Aldor-Noiman S., Feigin P., Mandelbaum A. Workload forecasting for a call center: Methodology and a case study // *The Annals of Applied Statistics*. 2010, vol. 3 (4), pp. 1403-1447.
9. Chih-Chung Chang, Chih-Jen Lin. *LIBSVM: A Library for Support Vector Machines. ACM Transactions on Intelligent Systems and Technology* (Taipei, November 29, 2019). Taiwan, National Taiwan University, 2019, pp. 1-24.
10. Haipeng Shen, Jianhua Z. Huang. Interday Forecasting and Intraday Updating of Call Center Arrivals. *Manufacturing & Service Operations Management*, 2008, no. 10(3), pp. 391-410.
11. Ming-Chi Tsai [and others]. Forecasting leading industry stock prices based on a hybrid time-series forecast model. *PLoS ONE* (Alessandro Spelta, Italy, December 31, 2018). Italy, Università Cattolica del Sacro Cuore, 2018, pp. 1-24.
12. Nicola Baldon. Time series Forecast of Call volume in Call Center using Statistical and Machine Learning Methods. *Degree project in computer science and engineering, second cycle, 30 credits Stockholm*. Sweden, 2019.