

УДК 336.66 DOI: 10.14451/1.240.150

Прогнозирование загруженности гостиниц с использованием методов машинного обучения

© 2024 Ильин Матвей Игоревич

Магистрант. Новосибирский национальный исследовательский государственный университет. Ведущий специалист по моделям предиктивной аналитики клиентских сервисов. ПАО «Группа Ренессанс Страхование».

E-mail: m.ilin@g.nsu.ru

© 2024 Писаренко Михаил Максимович

Студент. Новосибирский национальный исследовательский государственный университет.

E-mail: m.pisarenko@g.nsu.ru

Ключевые слова: гостиничный бизнес, модели машинного обучения, прогнозирование, описательный анализ, авторегрессионные модели, нейронные сети, управленческие решения.

Современный гостиничный бизнес сталкивается с множеством вызовов, среди которых важнейшим является эффективное управление загрузкой номерного фонда. Оптимальное прогнозирование загруженности гостиницы позволяет не только повысить доходность, но и улучшить качество обслуживания гостей, что в свою очередь способствует росту лояльности клиентов и положительных отзывов. Также управление загруженностью номерного фонда позволяет избегать кассовых разрывов при планировании финансовой нагрузки. Специфика гостиничного бизнеса такова, что основной финансовый поток от деятельности является авансами, которые гостиница использует в данный момент, тогда как непосредственно признание выручки происходит в момент заселения гостя. Таким образом, гостиница обеспечивает финансирование операционной деятельности за счёт будущих доходов, которые непосредственно связаны с будущей загрузкой.

С развитием информационных технологий и увеличением объема доступных данных появляются новые возможности для анализа и прогнозирования. Одним из наиболее перспективных подходов в данной области является использование методов машинного обучения (ML). Эти методы позволяют выявлять скрытые закономерности в больших объемах данных и формировать точные прогнозы на основе множества факторов, включая сезонность, тенденции спроса, события в регионе и другие переменные. Цель данной работы – исследование моделей машинного обучения для прогнозирования загруженности гостиницы. Для достижения этой цели планируется провести анализ существующих методов прогнозирования, а также изучить, как собираются и подготавливаются данные, строятся и тестируются модели машинного обучения. На основе полученных результатов может быть построена оценка точности и эффективности модели, а также разработаны рекомендации по ее применению в реальных условиях.

Предметом исследования данной работы являются методы машинного обучения, применяемые

для прогнозирования загрузки гостиниц. В частности, рассматриваются алгоритмы и модели, которые позволяют анализировать исторические данные о бронированиях, учитывать различные факторы, влияющие на спрос, и предсказывать будущую загрузку номерного фонда. Объектом исследования выступают гостиницы и их системы управления бронированиями. В рамках работы будут изучены реальные данные о работе гостиницы, включая информацию о бронированиях, ценовой политике, сезонных колебаниях, маркетинговых акциях и других аспектах, влияющих на уровень загрузки.

Гостиничный бизнес имеет уникальную специфику финансового планирования и управления, связанную с предоплатами за бронирования. Часто гостиницы получают авансовые платежи за бронирования, которые будут реализованы только через 1–2 месяца. Это создаёт ситуацию, при которой текущая операционная деятельность, включая выплату заработных плат, закупку расходных материалов и другие ежедневные расходы, финансируется за счёт будущей загрузки гостиниц. Таким образом, точное прогнозирование загрузки становится критически важным для поддержания стабильности и непрерывности бизнес-процессов, а также позволяет избегать кассовых разрывов.

Используемая терминология

Полученные авансы за бронирования – авансовые платежи на проживание в следующих месяцах. В данном сценарии наблюдается снижение авансовых платежей.

Фактические доходы от проживания – доходы от проживших гостей в текущем месяце.

Операционные расходы – расходы на зарплаты, закупку материалов и другие текущие затраты. В июне эти расходы значительно увеличиваются.

Чистый денежный поток – разница между общими поступлениями (авансы и фактические доходы) и операционными расходами.

Разрывы возникают, потому что зимой гостиница получала большие авансы на проживание летом. Зимой операционные расходы гостиницы существенно ниже, чем летом, это объясняется низкой загруженностью гостями в это время года. Летом загруженность выросла, а вместе

с ней и текущие расходы (фонд оплаты труда, расходные материалы), но денежные средства компания получила ранее, а новые авансовые платежи на проживание осенью ниже аналогичного показателя зимой, опять же в силу сезонности.

Чтобы избежать невыплат, компания должна была предвидеть такую проблему и сохранить часть накоплений на выплаты летом, то есть отказаться от реинвестирования, выплат дивидендов или погашения кредитов зимой на величину кассового разрыва летом. А величину кассового разрыва реально оценить, только в случае, когда возможно с высокой степенью точности спрогнозировать загруженность гостями на осень.

Этот пример более точно демонстрирует кассовый разрыв и подчёркивает важность точного прогнозирования загрузки гостиниц для предотвращения финансовых проблем.

Использование методов машинного обучения в этой области позволяет существенно улучшить точность прогнозов, обеспечивая более эффективное управление ресурсами и финансовыми потоками, что, в свою очередь, способствует устойчивому развитию гостиничного бизнеса.

Помимо основной проблемы, описанной выше, существуют и другие, не менее важные причины прогнозировать загруженность:

– Оптимизация доходов

Прогнозирование позволяет гостинице устанавливать динамические цены в зависимости от ожидаемого спроса. Это помогает максимизировать доходы, повышая цены в периоды высокой загрузки и предлагая скидки в периоды

низкой загрузки для привлечения большего числа гостей.

- Эффективное управление персоналом
Знание предполагаемой загрузки помогает лучше планировать графики работы персонала, избегая как недокомплектации, так и избыточного количества сотрудников. Это способствует повышению качества обслуживания и снижению затрат на оплату труда.
- Планирование закупок и управления запасами
Прогнозирование позволяет точно планировать закупки необходимых расходных материалов и продуктов, предотвращая как их дефицит, так и избыточные запасы, что оптимизирует затраты и улучшает обслуживание клиентов.
- Улучшение клиентского опыта
Знание предстоящей загрузки позволяет улучшить планирование мероприятий, программ анимации и других активностей для гостей, обеспечивая их высокое качество и соответствие ожиданиям клиентов.
- Стратегическое планирование и маркетинг
Прогнозирование спроса помогает разрабатывать эффективные маркетинговые стратегии, направленные на привлечение гостей в периоды низкой загрузки и удержание постоянных клиентов в периоды высокой загрузки.

Прогнозирование временных рядов является ключевым инструментом для анализа данных, которые изменяются во времени, и имеет широкое применение в различных областях, включая гостиничный бизнес. Существует множество методов прогнозирования временных рядов, которые можно разделить на классические статистические методы и методы машинного обучения.

Метод скользящего среднего – это один из наиболее простых методов прогнозирования временных рядов. Он основывается на идее сглаживания данных путем усреднения значений за определенный период времени.

Преимущества метода скользящего среднего включают его простоту и способность сгладить

шум в данных, что делает тренды и основные паттерны более видимыми. Однако он также имеет свои ограничения, такие как отстающая реакция на изменения и потеря данных на краях временного ряда из-за нехватки точек данных для усреднения.

Метод экспоненциального сглаживания придает большее значение недавним наблюдениям, что делает его более чувствительным к последним изменениям в данных. Варианты этого метода, такие как модель Хольта-Винтерса, позволяют учитывать тренды и сезонные колебания.

Авторегрессионная модель (AR) – это метод прогнозирования временных рядов, который основывается на предположении о том, что текущее значение ряда зависит от предыдущих значений этого же ряда. Одним из главных преимуществ этого метода является его способность учитывать временные закономерности и тренды, используя информацию о предыдущих значениях ряда.

Авторегрессионная модель также имеет свои недостатки. В частности, она может быть чувствительна к выбросам или аномалиям в данных, что может привести к искажению результатов прогнозирования. Кроме того, AR предполагает стационарность данных, что может быть неверным для некоторых временных рядов, особенно в случае сезонных или циклических изменений. Это ограничение может снизить точность прогнозов или потребовать дополнительной обработки данных перед использованием модели.

Модель скользящего среднего (MA) – это метод анализа временных рядов, который использует прошлые ошибки прогнозирования для улучшения текущих прогнозов. Одним из главных преимуществ этого метода является его способность сглаживать краткосрочные колебания и шумы в данных, что позволяет выявить основные тренды и паттерны. Такой подход делает MA полезным инструментом для анализа временных рядов с выраженными краткосрочными флуктуациями.

Однако у модели скользящего среднего также

есть свои ограничения. В частности, она может оказаться неэффективной для прогнозирования временных рядов с длительными или сложными трендами, поскольку склонна учитывать только последние ошибки прогнозирования. Это может привести к недооценке будущих значений ряда, особенно в случае, если тренды изменяются с течением времени. Кроме того, модель скользящего среднего не учитывает структуру данных, такую как сезонность или цикличность, что может снижать ее точность в анализе временных рядов с выраженными сезонными паттернами.

Модель ARIMA комбинирует авторегрессию, скользящее среднее и интеграцию (разности временного ряда)

Линейная регрессия – это один из наиболее простых и широко используемых методов прогнозирования, который моделирует зависимость между зависимой переменной и одной или несколькими независимыми переменными. Линейная регрессия позволяет проводить интерпретацию влияния каждой независимой переменной на зависимую переменную, что делает ее полезной для выявления основных факторов, влияющих на исследуемый процесс или явление.

Однако у линейной регрессии есть и свои недостатки. В частности, этот метод предполагает линейную зависимость между переменными, что может быть неверным для некоторых данных с нелинейными взаимосвязями. Это может привести к недооценке или переоценке эффектов переменных и искажению результатов анализа. Кроме того, линейная регрессия может быть чувствительна к выбросам или аномалиям в данных, что может снижать ее точность в прогнозировании.

Деревья решений и ансамблевые методы – это семейство алгоритмов машинного обучения, которые используются для классификации и регрессии путем построения деревьев принятия решений или комбинации нескольких деревьев.

Одним из главных преимуществ деревьев решений является их простота и интерпретируемость. Деревья решений позволяют легко визу-

ализировать принятые решения и понять, какие признаки являются наиболее важными для классификации или регрессии. Кроме того, деревья решений могут обрабатывать как числовые, так и категориальные данные, что делает их универсальным инструментом для анализа различных типов данных.

Однако деревья решений также имеют свои недостатки. В частности, они могут быть склонны к переобучению, особенно если деревья слишком глубокие или содержат слишком много признаков. Это может привести к недостаточной обобщающей способности модели и плохой производительности на новых данных. Кроме того, деревья решений могут быть неустойчивы к небольшим изменениям в данных, что может привести к изменению структуры дерева и результатам классификации.

Ансамблевые методы, такие как случайный лес и градиентный бустинг, представляют собой комбинацию нескольких деревьев решений с целью повышения точности и стабильности модели. Они могут снизить склонность к переобучению и улучшить обобщающую способность модели путем усреднения результатов нескольких базовых моделей. Тем не менее, ансамблевые методы требуют больше вычислительных ресурсов и времени для обучения, чем отдельные деревья решений, что может быть недоступно для больших наборов данных или при ограниченных вычислительных мощностях.

Метод опорных векторов (SVM) представляет собой алгоритм машинного обучения, который используется как для задач классификации, так и для регрессии. Он основан на принципе поиска оптимальной разделяющей гиперплоскости между классами данных. Основное преимущество SVM заключается в его способности эффективно работать в пространствах высокой размерности, что делает его подходящим для работы с данными, которые нелинейно разделимы.

Одним из ключевых преимуществ SVM является его способность обрабатывать как линейные, так и нелинейные данные, используя ядерные

функции для преобразования их в более высокие размерности. Это позволяет моделировать сложные нелинейные зависимости между переменными и повышает точность классификации или регрессии. Кроме того, SVM имеет небольшое количество гиперпараметров, что облегчает его настройку и использование в практических задачах.

Однако у SVM также есть свои ограничения. В частности, для больших наборов данных и большого числа признаков SVM может потребовать значительных вычислительных ресурсов и времени для обучения. Кроме того, SVM чувствителен к выбору ядерной функции и ее параметров, что может потребовать тщательной настройки модели для достижения оптимальных результатов.

Нейронные сети, особенно рекуррентные нейронные сети (RNN) и их варианты, такие как LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), широко используются для прогнозирования временных рядов благодаря своей способности учитывать длительные зависимости и сложные паттерны в данных.

Гибридные методы комбинируют классические статистические методы и методы машинного обучения для повышения точности прогнозов. Например, комбинация ARIMA и нейронных сетей может использоваться для моделирования различных аспектов временного ряда.

Каждый из методов прогнозирования временных рядов имеет свои преимущества и ограничения. Выбор метода зависит от характера данных, наличия сезонных и трендовых компонентов, а также от требований к точности и интерпретируемости моделей. Использование машинного обучения для прогнозирования загрузки гостиниц представляет значительные преимущества, позволяя учитывать сложные и нелинейные зависимости, что способствует более точному и надежному прогнозированию.

Рассмотрим ключевые исследования, посвященные этой теме.

Пан и Ян в своей работе *Forecasting destination weekly hotel occupancy with big data* анализируют возможность использования больших данных для прогнозирования недельной загрузки гостиниц. Они подчеркивают важность интеграции данных из различных источников, таких как социальные медиа, погодные условия и данные бронирования, для повышения точности прогнозов. Использование больших данных позволяет моделям машинного обучения учитывать множество факторов, влияющих на загрузку гостиниц, что улучшает их предсказательную способность.

Исследование Чжана и соавторов *Weekly hotel occupancy forecasting of a tourism destination* развивает эту тему, рассматривая устойчивость прогнозов на основе данных, собранных из туристических направлений. Они используют различные методы машинного обучения, такие как градиентный бустинг и случайные леса, для построения моделей прогнозирования. Их результаты показывают, что модели машинного обучения превосходят традиционные статистические методы, особенно в условиях изменяющегося туристического спроса.

Ло в работе *Room occupancy rate forecasting: a neural network approach* одним из первых предложил использовать нейронные сети для прогнозирования загрузки гостиниц. Его исследования показывают, что нейронные сети могут успешно моделировать сложные зависимости между различными переменными, влияющими на загрузку гостиниц, и предоставлять точные прогнозы. Это исследование заложило основу для дальнейшего использования нейронных сетей в гостиничном бизнесе.

Захари и соавторы в своей работе *Forecasting hotel arrivals and occupancy using Monte Carlo simulation* применили метод Монте-Карло для прогнозирования прибытия и загрузки гостиниц. Этот метод позволяет учитывать неопределенности и вариативность данных, что делает прогнозы более надежными. Они показали, что использование симуляционных методов может значительно улучшить точность прогнозирования в условиях неопределенности.

Шварц и соавторы в исследовании *Hotel daily occupancy forecasting with competitive sets: a recursive algorithm* предложили рекурсивный алгоритм для ежедневного прогнозирования загрузки гостиниц. Они используют данные о конкурентах для улучшения точности своих прогнозов. Их подход позволяет учитывать влияние конкурентной среды на загрузку гостиниц, что особенно важно в высококонкурентных туристических рынках.

Чжан и соавторы в работе *Improving daily occupancy forecasting accuracy for hotels based on EEMD-ARIMA model* исследуют комбинированный подход, использующий расширенное модальное разложение (EEMD) и модель ARIMA для улучшения точности ежедневных прогнозов загрузки. Их подход показывает, что комбинирование методов может привести к значительным улучшениям в прогнозировании, особенно при наличии сезонных и циклических колебаний спроса.

Каиседо-Торрес и Пайярес в своей работе *A machine learning model for occupancy rates and demand forecasting in the hospitality industry* представили модель машинного обучения для прогнозирования коэффициентов загрузки и спроса в гостиничном бизнесе. Они показывают, что использование алгоритмов машинного обучения, таких как деревья решений и случайные леса, может значительно улучшить точность прогнозов по сравнению с традиционными методами.

Ло в исследовании *Initially testing an improved extrapolative hotel room occupancy rate forecasting technique* провел первоначальное тестирование улучшенной техники экстраполятивного прогнозирования загрузки гостиничных номеров. Он использует комбинацию традиционных методов и новых подходов для повышения точности прогнозов, показывая, что даже незначительные улучшения в методологии могут привести к значительным результатам.

Деса и Марзуки в работе *A comparison of forecasting methods for hotel room occupancy* сравнили различные методы прогнозирования загрузки гостиниц, включая статистические мето-

ды и модели машинного обучения. Их результаты подчеркивают, что модели машинного обучения, такие как нейронные сети и случайные леса, часто превосходят традиционные методы, особенно в условиях изменяющегося туристического спроса.

Наконец, Чанг и соавторы в работе *Forecasting hotel room occupancy using long short-term memory networks with sentiment analysis and scores of customer online reviews* применяют модели долгосрочной краткосрочной памяти (LSTM) в сочетании с анализом настроений (сентимент анализ) и оценками отзывов клиентов для прогнозирования загрузки гостиниц. Их результаты демонстрируют, что учет мнений клиентов, выраженных в онлайн-отзывах, может значительно повысить точность прогнозов. Этот подход показывает важность интеграции качественных данных из социальных медиа в модели машинного обучения.

Классификация гостиниц является важной частью гостиничного бизнеса, позволяющей гостям лучше ориентироваться в разнообразии предложений, а отелям – эффективно управлять своими услугами и маркетинговыми стратегиями. Типы гостиниц можно классифицировать по различным критериям: по уровню обслуживания, целевой аудитории, местоположению, длительности пребывания, а также по особым характеристикам и специализациям.

Варианты классификации

– По уровню обслуживания.

Эконом-класс: гостиницы данного типа предлагают базовые удобства по минимальной цене. Чаще всего это небольшие комнаты с основными удобствами, без дополнительных услуг.

Средний класс: гостиницы среднего класса предоставляют более широкий набор услуг и удобств по умеренной цене. Это может включать рестораны, конференц-залы, фитнес-центры и другие дополнительные услуги.

Премиум-класс: гостиницы премиум-класса предлагают высокий уровень комфорта и сервиса, включая эксклюзивные услуги и удоб-

- ства. Такие гостиницы часто располагаются в престижных районах и ориентированы на состоятельных клиентов.
- По целевой аудитории. Бизнес-гостиницы ориентированы на деловых путешественников. Они часто располагаются в деловых районах города и предлагают услуги, необходимые для работы, такие как конференц-залы, Wi-Fi, бизнес-центры. Туристические гостиницы предназначены для туристов и отдыхающих. Они могут располагаться вблизи туристических достопримечательностей и предлагать экскурсии, развлекательные программы и другие услуги для туристов. Спа-отели специализируются на оздоровительных и спа-услугах, таких как массажи, процедуры по уходу за телом и лицом, термальные источники. Они часто располагаются в курортных зонах.
 - По местоположению. Городские гостиницы находятся в городах, часто в центральных или деловых районах. Они ориентированы как на деловых путешественников, так и на туристов. Курортные гостиницы располагаются в курортных зонах, таких как побережья, горные районы или на природных курортах. Эти гостиницы предлагают широкий спектр развлечений и услуг для отдыха. Аэропортовые гостиницы находятся в непосредственной близости от аэропортов и предназначены для путешественников, которым нужно переночевать перед или после полета.
 - По длительности пребывания. Гостиницы для краткосрочного пребывания ориентированы на гостей, которые останавливаются на короткий срок (одну или несколько ночей). Чаще всего это городские или аэропортовые гостиницы. Апартаменты предназначены для длительного проживания. Они предлагают номера с кухнями и другими удобствами, необходимыми для долгосрочного проживания. Загруженность гостиницы зависит от множества факторов, которые можно разделить на внешние и внутренние. Внешние факторы – это те, которые гостиница не может контролировать, но должна учитывать в своем стратегическом планировании. Внутренние факторы касаются управленческих решений и качества предоставляемых услуг.
 - Внешние факторы.
 - Сезонность. Время года оказывает значительное влияние на уровень загрузки гостиниц. В курортных зонах пик посещаемости приходится на определенные сезоны (лето для пляжных курортов и зима для горнолыжных курортов). В городских гостиницах, ориентированных на деловой туризм, загрузка может быть выше в будние дни и ниже в выходные.
 - Экономическая ситуация. Экономические условия в стране и мире могут влиять на туристический поток. В периоды экономических спадов люди меньше путешествуют, что снижает загрузку гостиниц. Напротив, в периоды экономического роста туристическая активность возрастает.
 - Политическая обстановка. Политическая стабильность и безопасность региона сильно влияют на туристическую привлекательность. Политические кризисы, протесты или террористические угрозы могут резко снизить количество туристов.
 - События и мероприятия. Проведение крупных мероприятий (конференций, выставок, спортивных событий) может значительно увеличить загрузку гостиниц в определенный период. Гостиницы вблизи мест проведения таких мероприятий обычно наблюдают повышенный спрос.
 - Климатические условия. Погодные условия могут повлиять на решение туристов путешествовать. Например, экстремальные погодные явления (ураганы, наводнения) могут снизить туристическую активность. Также благоприятная погода положительно влияет на загруженность загородных отелей выходного дня.
 - Конкуренция. Наличие конкурирующих гостиниц в регионе и их ценовая политика также влияют на загрузку. Гостиницы должны учитывать конкурентные цены и предложения для поддержания своей привлекательности.
 - Внутренние факторы.

Ценообразование. Цены на номера и дополнительные услуги играют ключевую роль в привлечении клиентов. Гибкая ценовая политика, включая скидки и специальные предложения, может повысить загрузку.

Качество обслуживания. Высокий уровень обслуживания и положительные отзывы клиентов способствуют возврату гостей и привлечению новых клиентов. Гостиницы, предоставляющие высококачественные услуги, имеют более высокую загрузку.

Маркетинг и реклама. Эффективные маркетинговые кампании и рекламные стратегии помогают увеличить осведомленность о гостинице и привлекать больше гостей. Использование онлайн-платформ и социальных медиа для продвижения играет важную роль в современном маркетинге.

Локация. Местоположение гостиницы влияет на ее привлекательность. Гостиницы, расположенные вблизи популярных туристических объектов, деловых центров или транспортных узлов, обычно имеют более высокую загрузку.

Инфраструктура и удобства. Наличие современных удобств (Wi-Fi, бассейн, фитнес-центр, ресторан) и качественной инфраструктуры (удобные номера, конференц-залы) повышает конкурентоспособность гостиницы.

Управленческие решения. Эффективное управление гостиницей, включая планирование и прогнозирование спроса, обучение персонала и внедрение инновационных технологий, способствует увеличению загрузки. Отзывы гостей. Отзывы гостей влияют на процесс выбора отеля в будущем как положительно, так и отрицательно.

Понимание и учет этих факторов позволяет гостиницам разрабатывать стратегии, направленные на оптимизацию загрузки и улучшение финансовых показателей. Анализ этих факторов также важен для разработки моделей машинного обучения для прогнозирования загрузки гостиниц, так как учет большего количества переменных может значительно повысить точность прогнозов.

Библиографический список

1. *Ampountolas A.* Modeling and forecasting daily hotel demand: A comparison based on SARIMAX, neural networks, and GARCH models // *Forecasting*. – 2021. – Vol. 3, no. 3. – P. 580–595.
2. *Ampountolas A., Legg M.* Predicting daily hotel occupancy: a practical application for independent hotels // *Journal of Revenue and Pricing Management*. – 2023. – P. 1–9.
3. *Caicedo-Torres W., Payares F.* A machine learning model for occupancy rates and demand forecasting in the hospitality industry // *Advances in Artificial Intelligence-IBERAMIA 2016 : 15th Ibero-American Conference on AI, San José, Costa Rica, November 23-25 2016, Proceedings 15*. – Springer International Publishing, 2016. – P. 201–211.
4. *Desa N., Marzuki M.* A comparison of forecasting methods for hotel room occupancy // *AIP Conference Proceedings*. – 2019. – Aug. – Vol. 2138. – P. 050009. – DOI: [10.1063/1.5121114](https://doi.org/10.1063/1.5121114).
5. Forecasting Hotel Room Occupancy Using Long Short-Term Memory Networks with Sentiment Analysis and Scores of Customer Online Reviews / Y.-M. Chang [et al.] // *Applied Sciences*. – 2021. – Nov. – Vol. 11. – P. 10291. – DOI: [10.3390/app112110291](https://doi.org/10.3390/app112110291).
6. Hotel daily occupancy forecasting with competitive sets: a recursive algorithm / Z. Schwartz [et al.] // *International Journal of Contemporary Hospitality Management*. – 2016. – Feb. – Vol. 28. – P. 267–285. – DOI: [10.1108/IJCHM-10-2014-0507](https://doi.org/10.1108/IJCHM-10-2014-0507).
7. Improving daily occupancy forecasting accuracy for hotels based on EEMD-ARIMA model / G. Zhang [et al.] // *Tourism Economics*. – 2017. – Apr. – Vol. 23. – DOI: [10.1177/1354816617706852](https://doi.org/10.1177/1354816617706852).
8. Law R. Room occupancy rate forecasting: a neural network approach // *International Journal of Contemporary Hospitality Management*. – 1998. – Vol. 10, no. 6. – P. 234–239.
9. Law R. Initially Testing an Improved Extrapolative Hotel Room Occupancy Rate Forecasting Technique // *Journal of Travel & Tourism Marketing*. – 2004. – July. – Vol. 16. – P. 71–77. – DOI: [10.1300/J073v16n02_06](https://doi.org/10.1300/J073v16n02_06).
10. Pan B. Y. Y. Forecasting destination weekly hotel occupancy with big data // *Journal of Travel Research*. – 2017. – Vol. 56, no. 7. – P. 957–970.
11. Weekly Hotel Occupancy Forecasting of a Tourism Destination / M. Zhang [et al.] // *Sustainability*. – 2018. – Nov. – Vol. 10. – P. 4351. – DOI: [10.3390/su10124351](https://doi.org/10.3390/su10124351).
12. *Zakhary A., El-Shishiny H., Gayar N.* Forecasting hotel arrivals and occupancy using Monte Carlo simulation // *Journal of Revenue & Pricing Management*. – 2009. – May. – Vol. 10. – DOI: [10.1057/rpm.2009.42](https://doi.org/10.1057/rpm.2009.42).