

**Объединенный институт ядерных исследований**  
**Лаборатория информационных технологий**

Осетров Евгений Сергеевич

**МАТЕМАТИЧЕСКИЕ МОДЕЛИ, МЕТОДЫ И  
АЛГОРИТМЫ ДЛЯ ПРОГНОЗИРОВАНИЯ  
ПАССАЖИРСКИХ ПЕРЕВОЗОК**

Специальность 05.13.18  
Математическое моделирование,  
численные методы и комплексы программ

Диссертация на соискание ученой степени  
кандидата физико-математических наук

Научный руководитель: доктор физ.-мат. наук, В.В.Иванов

Дубна – 2018

# Содержание

<b>Введение</b>	<b>5</b>
<b>1 Анализ применяемых на практике методов и подходов для определения, оценки изменений и прогнозирования пассажирских перевозок</b>	<b>17</b>
1.1 Существующая структура показателей измерения и характеристик транспортного спроса . . . . .	17
1.2 Методологии оценки изменений транспортного спроса . .	21
1.2.1 Основные этапы прогнозирования изменений транспортного спроса . . . . .	21
1.2.2 Изменение спроса на транспортные услуги за счёт изменения транспортной подвижности населения .	23
1.2.3 Изменение спроса на транспортные услуги для пассажиров за счёт индуцированного спроса, связанного с изменением транспортной инфраструктуры . . . . .	30
1.2.4 Изменение спроса на транспортные услуги за счёт перераспределения пассажиров между видами транспорта . . . . .	31
1.3 Анализ теоретических аспектов современной методологии прогнозирования транспортного спроса . . . . .	37
1.4 Анализ возможностей применения показателя энергопотребления в качестве фактора для прогнозирования изменений объемов пассажирских перевозок в регионе . . .	45
1.5 Выводы к Главе 1 . . . . .	51
<b>2 Прогнозирование пассажирских перевозок в Московском метрополитене с помощью ИНС прямого типа</b>	<b>54</b>
2.1 Анализ данных наблюдения и постановка задачи . . . . .	54
2.2 Анализ временного ряда, описывающего объемы перевозок пассажиров . . . . .	55
2.3 Анализ факторов, влияющих на суточные объемы пассажирских перевозок . . . . .	57

2.4	Постановка задачи . . . . .	60
2.5	Прогнозирование пассажирских перевозок с помощью ИНС прямоточного типа . . . . .	61
2.5.1	Архитектура и основные принципы работы мно- гослойного перцептрона (МСП) . . . . .	61
2.5.2	Структура сети и первые результаты прогнози- рования . . . . .	64
2.6	Вейвлет-фильтрация суточных объемов пассажирских пе- ревозок . . . . .	66
2.6.1	Общая схема вейвлет-фильтрации . . . . .	67
2.6.2	Вейвлет-фильтрация измерений пассажиропотока	69
2.7	Анализ полученных результатов . . . . .	73
2.8	Выводы к Главе 2 . . . . .	75
<b>3</b>	<b>Прогнозирование суточного потребления электроэнергии в Московской агломерации</b>	<b>77</b>
3.1	Динамика энергопотребления в Московской агломерации	77
3.2	Структура ИНС, используемой для прогнозирования энер- гопотребления в Московской агломерации . . . . .	81
3.3	Базовый алгоритм метода “Гусеница”-SSA . . . . .	82
3.3.1	Первый этап: разложение . . . . .	82
3.3.2	Второй этап: восстановление . . . . .	84
3.4	Вычисление прогнозной части файла “подсказка” . . . . .	86
3.5	Прогнозирование энергопотребления в Московском аг- гломерации с помощью рекуррентной ИНС . . . . .	88
3.6	Прогнозирование потребления электроэнергии в Москов- ской агломерации в подходе “Гусеница”-SSA . . . . .	90
3.7	Обсуждение полученных результатов . . . . .	95
3.8	Выводы к Главе 3 . . . . .	96
<b>4</b>	<b>Прогнозирование пассажирских перевозок в Москов- ском метрополитене на основе совместного использо- вания ИНС и сингулярно-спектрального анализа</b>	<b>99</b>
4.1	Предпосылки и исходные данные для прогнозирования .	99
4.2	Прогнозирование пассажирских перевозок с помощью ре- куррентной ИНС . . . . .	100

4.3	Прогнозирование пассажирских перевозок в ММ на основе сингулярно-спектрального анализа (подход “Гусеница”-SSA) . . . . .	102
4.4	Сравнительный анализ результатов, полученных разными методами . . . . .	107
4.5	Выводы к Главе 4 . . . . .	109
	<b>Заключение</b>	<b>111</b>
	<b>Список литературы</b>	<b>117</b>

## Введение

Транспорт – это одно из ключевых средств развития экономики и социума, а его влияние на жизнь государства разнообразно и многопланово. Транспорт способствует прогрессивным географическим и структурным сдвигам в размещении производства и населения, росту производительности труда, повышению уровня жизни населения. Обеспечивая международное разделение труда, массовый туризм и культурный обмен, транспорт способствует крупным изменениям в экономике и культуре.

С помощью транспорта углубляется специализация и расширяется кооперирование промышленного и сельскохозяйственного производства, укрепляется экономическое положение государства. Транспорт является основой эффективного развития экономики государства и регионов, поскольку выполняет коммуникативную функцию, обеспечивая тем самым интенсификацию товарообмена, рост производительных сил и рациональное распределение ресурсов между факторами производства (экономическими ресурсами, необходимыми для производства товаров и услуг) [1].

Получение оперативной информации о состоянии и прогнозе изменений объемов пассажирских перевозок и спроса на транспортные услуги является актуальной задачей современного общества. Ее решение способствует удовлетворению потребностей населения в передвижении путем оптимального использования транспорта, повышает эффективность управления транспортной системой.

В качестве объекта исследования выбрано изменение объемов перевозок пассажиров Московским метрополитеном и ряд факторов, на него влияющих, представленных в виде временных рядов с шагом наблюдения одни сутки.

Предметом исследования является разработка и оптимизация математических моделей, методов, алгоритмов и вычислительных схем, обеспечивающих достоверное прогнозирование изменений объемов перевозок пассажиров Московским метрополитеном в краткосрочной и среднесрочной перспективах.

Разработкам и применению математических моделей, а также их программное или аппаратное применение с использованием искусствен-

ных нейронных сетей для прогнозирования в различных отраслях и областях знаний уделено большое внимание в трудах многих российских и зарубежных исследователей: Беркинблит М.Б. [2], Вороновский Г.К. [3], Голубев Ю.Ф. [4], Горбань А.Н [5], [6], [7], Еремин Д.М. [8], Каллан Р. [9], Круглов В.В. [10], Миркес Е.М. [11], Осовский С. [12], Савельев А.В. [13], Сигеру О., Марзуки Х. [14], Тадеусевич Р., Боровик Б. [15], Терехов В.А., Ефимов Д.В. [16], Уоссермен Ф. [17], Хайкин С. [18].

Теоретические аспекты изучения возможностей применения искусственных нейронных сетей для построения моделей, описывающих и характеризующих изменения состояний транспортных систем, прогнозирования их развития, которые имеют механизм адаптации к условиям инфраструктуры городов и регионов, рассмотрены в работах отечественных и зарубежных авторов: Пронин С.В. [19], Murat Cuhadar, Iclal Cogurcu [20], K.S. Swarnalatha [21], Глушков С.В. [22], [23], Барский А.Б. [24], [25], Rodrigue J.P. [26], Smith, B.L., Demetsky M.J. [27], Vlahogianni E.I. [28], Dougherty M. [29], Ledoux C. [30], Yin H., Wong SC. [31], Zhejun G. [32].

Практическая реализация подходов и проведение первых экспериментов, связанных с применением искусственных нейронных сетей при прогнозировании объемов пассажирских перевозок (в том числе железнодорожного транспорта), рассмотрено в результатах прикладных исследований отечественных и зарубежных авторов: Апатцев В.И. [33], Ali Payidar Akgungor [34], Nam, K., Schaefer, T. [35], Robert L. Cook [36], Tsung-Hsien Tsai [37], Fu L., Rilett L.R. [38], Ishak S., Kotha P. [39], Claveria O. [40], Zhang G.P. [41].

Таким образом, многие ученые своими исследованиями подтверждают, что использование искусственных нейросетевых технологий и моделей в транспортной отрасли является средством повышения эффективности управления сложными динамическими, социально-экономическими и организационными системами различных отраслей деятельности и самого разного масштаба. И в то же время, как показывает проведенный автором анализ существующих методологических подходов к прогнозированию динамики объемов пассажирских перевозок недостаточно развит или почти не применяется интегрированный

подход, с использованием искусственных нейронных сетей, к решению динамических задач прогнозирования временных рядов, характеризующих объем пассажирских перевозок и влияющих на него факторов в условиях неопределенности на краткосрочный и среднесрочный периоды времени.

Во **Введении** Формулируется постановка и концептуальная идея, решаемой в диссертационной работе задачи, отмечается ее важность и актуальность.

В **Главе 1** рассматриваются актуальные вопросы и проблемы использования современных подходов прогнозирования изменений объемов пассажирских перевозок и спроса на транспортные услуги, их возможности и ограничения. С помощью комплексного подхода, основанного на применении методов математической статистики и экономики, автором проводится анализ существующих подходов к прогнозированию изменений объемов пассажирских перевозок и спроса пассажиров на транспортные услуги (транспортный спрос). На основании проведенного анализа сформулированы условия применения схем прогнозирования и выявлены их особенности, возможности, сильные и слабые стороны, в том числе методики, учитывающие более одного вида транспорта, рассмотрены используемые на практике факторы, влияющие на объемы пассажирских перевозок и спрос на транспортные услуги.

На основании анализа существующих методик оценки и прогнозирования изменений объемов пассажирских перевозок и спроса на транспортные услуги, автором сделан вывод о том, что большинство из них могут и применяются для стратегического прогнозирования спроса на транспортные услуги (от одного года и более с временным шагом один год), что обусловлено периодичностью сбора и получения необходимой информации о влияющих на спрос факторах: численность населения, валовой региональный продукт (ВРП), среднедушевой доход и транспортная подвижность населения и другие. При этом оценки чувствительности потребностей пассажиров к различным факторам (социально-экономическим, финансовым, качественным характеристикам транспорта, инфраструктурным) являются частью прогнозирования изменений объемов пассажирских перевозок и спроса на

транспортные услуги.

В этой главе автором также показано, что валовой продукт транспортной системы пропорционален производству суммарного энергопотребления на коэффициент совершенства технологии, используемого в транспортной отрасли, а при одном и том же суммарном потреблении можно увеличить объем транспортных услуг в единицу времени за счёт роста коэффициента совершенствования технологий. Автором сделан вывод о том, что показатель энергопотребления в регионе или агломерации может выступать в качестве одного из факторов изменений объемов пассажирских перевозок, как характеристика транспортной подвижности населения и его активности в перемещениях в данном регионе. Показана актуальность и необходимость применения наряду с долгосрочными методами прогноза проведение среднесрочного и краткосрочного прогнозирования изменений объемов пассажирских перевозок и спроса на транспортные услуги, также их важность в обеспечении устойчивой работы транспортной системы.

Разработка методов краткосрочного прогнозирования изменений объемов пассажирских перевозок и транспортного спроса связана с учетом многих факторов, которые образуются как под действием причинно-следственных связей, так и по причине неопределенности. Последние усложняют задачу и требуют использовать в комплексе функциональные и вероятностно - статистические методы для получения конкретных решений. Решение данной проблемы может стать применение в качестве исходных данных для прогнозирования объемов пассажирских перевозок временных рядов, характеризующих динамику данного показателя за определённый период времени (время наблюдений), так и факторов влияющих на него в каждый интервал наблюдения.

Анализ временных рядов основан на предположении, что факторы, влиявшие на активность в прошлом и влияющие в настоящем, будут действовать и в будущем. Таким образом, анализ временных рядов может представлять собой эффективное средство для прогнозирования изменений объемов пассажирских перевозок. В качестве воздействующих факторов автором предполагается рассмотрение и анализ влияния таких факторов, которые ранее не использовались для



прогнозирования объемов пассажирских перевозок, а также оценить возможность их применения для математических моделей, методов и алгоритмов прогнозирования изменений объемов пассажирских перевозок.

Таким образом, автором в последующих главах будут рассматриваться вопросы использования математических методов анализа и прогнозирования временных рядов, которые смогут выступить в качестве альтернативного и эффективного инструмента прогнозирования краткосрочных и среднесрочных изменений объемов пассажирских перевозок в зависимости от подбираемых (предлагаемых автором к рассмотрению) факторов внешней среды и энергопотребления, как фактора характеризующего социальную и экономическую активность пассажиров, связанную с использованием рассматриваемой транспортной системы.

**Глава 2** посвящена рассмотрению задачи прогнозирования объемов пассажирских перевозок в Московском метрополитене с помощью искусственных нейронных сетей прямого типа.

Предварительный анализ исследуемых временных рядов показал, что объемы пассажирских перевозок существенно различаются по своим значениям в рабочие и в выходные-праздничные дни. В этой связи, для оценки возможностей прогноза с помощью ИНС нами использовались данные суточного объема пассажирских перевозок в рабочие дни.

Большие усилия были потрачены на этапе отбора тех факторов, которые могут влиять на динамику объемов пассажирских перевозок Московским метрополитеном. В результате проведенного анализа из полного набора 15 факторов были оставлены такие, которые играют ключевую роль в обучении ИНС.

ИНС с одним скрытым слоем плохо обучалась и, как следствие, с ее помощью невозможно было делать приемлемого прогноза. Поэтому использовался многослойный перцептрон с двумя скрытыми слоями, применение которого к исходным данным показало, что прогнозирование на основе ИНС возможно. Однако достигнутой при этом точности вряд ли можно было считать удовлетворительной. Для того, чтобы повысить точность и увеличить горизонт прогноза можно пред-

варительно, до обучения ИНС, провести фильтрацию анализируемого временного ряда, с целью исключения из него шумовой компоненты. В настоящей работе для исключения шума из анализируемого ряда использовалась дискретная вейвлет-фильтрация. Показано, что данная процедура позволяет более, чем в четыре раза повысить точность прогноза и, как следствие, существенно увеличить горизонт прогноза.

С учетом полученных теоретических выводов о наличии взаимосвязи между энергопотреблением и объемами пассажирских перевозок, которые подтвердили проведенные автором исследования корреляционной зависимости между переменной суточного потребления электрической энергии в Московской агломерации (г. Москва и Московская область) и изменения объемов перевозок пассажиров метрополитеном, мы сделали вывод, что показатель энергопотребления в регионе может выступать в качестве одного из значимых факторов изменений объемов пассажирских перевозок, как характеристика транспортной подвижности населения и его активности в перемещениях в данном регионе. Фактор энергопотребления интегрально характеризует социальную и экономическую активность населения в регионе, которая, в свою очередь, влияет на потребность в перемещении, в том числе, с использованием одного из ключевых видов транспорта – метрополитена. Таким образом, в данном исследовании фактор энергопотребления в регионе является одним из ключевых факторов, от которого зависит суточное изменение пассажирских перевозок, и от точности его определения и прогнозирования его изменения зависит точность и эффективность прогнозирования пассажирских перевозок. Поэтому в нашей методике для прогнозирования пассажирских перевозок в метрополитене с помощью ИНС, предварительно нужно выполнить прогноз суточного энергопотребления в Московской агломерации. Изучению данного вопроса посвящена Глава 3.

В **Главе 3** показано, что задача прогнозирования суточного энергопотребления для Московской агломерации может быть принципиально решена с помощью искусственных нейронных сетей.

Исходные данные суточного потребления электрической энергии в Московской агломерации представляют собой временной ряд наблюдений за последние 14 лет (всего 5114 наблюдений). Принимая во

внимание тот факт, что в главе 2 прогнозирование суточных объемов пассажирских перевозок в метрополитене проводилось только в будние дни, из исходного ряда суточных наблюдений потребления электрической энергии были исключены выходные дни. После исключения из исходных данных выходных дней, рассматриваемый временной ряд стал менее зашумленным. Кроме того, как и в случае суточных объемов пассажирских перевозок, этот ряд был подвергнут процедуре вейвлет-фильтрации для исключения из него высокочастотного шума. Как было показано выше, исключение из этих измерений указанного шума позволяет повысить точность и увеличить перспективу прогноза. Также, как и в главе 2, для определения возможного количества отбрасываемых вейвлет-коэффициентов и оценки горизонта прогноза, анализировалось поведение линейной автокорреляционной функции.

Важную роль в успешном решении рассматриваемой задачи сыграли следующие факторы: 1) оптимально подобранная архитектура ИНС, 2) адекватная структура выборки, подаваемой на вход сети, как на этапе обучения ИНС, так и при ее тестировании, 3) оригинально построенные процедуры обучения и прогнозирования сети.

Первые три переменные, подаваемые на вход ИНС, отвечали за сезонные и периодические колебания энергопотребления в Московской агломерации. Особо следует отметить 4-ую переменную, играющую роль своеобразной “подсказки” для ИНС, которая бралась из отфильтрованных данных (на этапе обучения сети) и из прогнозных значений, вычисленных с помощью пакета “Гусеница”-SSA [42], (на этапе тестирования сети). Последняя (пятая) переменная представляла собой величину, взятую из исходного ряда (на этапе обучения сети), либо то значение, которое предсказывалось на текущий день обученной ИНС (на этапе тестирования сети), тем самым была достигнута реализация прогнозирования с использованием ИНС рекуррентного типа (прогнозные ИНС значения на каждом шаге прогнозирования подавались обратно на вход ИНС, таким образом, после обучения ИНС на тестовой выборке, обучение осуществлялось на прогнозных значениях).

Нами был сделан вывод о том, что сформированная таким образом входная выборка и последовательность этапов вычислений позво-

лили: 1) достичь быстрого и эффективного обучения нейронной сети, а также 2) обеспечить приемлемую точность среднесрочного прогнозирования суточного энергопотребления для Московской агломерации.

Учитывая то, что подход, реализованный в пакете “Гусеница”-SSA [43, 44], предоставляет дополнительные возможности для детального анализа исследуемых временных процессов, показано сравнение результатов по прогнозированию суточного энергопотребления Московской агломерацией а на основе ИНС с тем, чего можно достичь, используя только методику, развитую в подходе “Гусеница”-SSA.

В данном разделе была исследована возможность проведения среднесрочного прогноза суточного потребления электроэнергии на основе методики, реализованной в подходе “Гусеница”-SSA. Наши ожидания о том, что в этом случае точность прогноза и его горизонт должны несколько уступать тому, что было получено в Главе 2, не оправдались. Проведенные нами исследования показали, что прогнозирование, реализованное на основе методики “Гусеница”-SSA, хорошо согласуется с результатами с результатами прогноза с помощью ИНС.

С учетом результатов, изложенных в данной главе и развитой методики прогнозирования на основе ИНС, нам удалось построить вычислительную схему, позволившую обеспечить успешное прогнозирование пассажиропотока в Московском метрополитене в среднесрочной перспективе. При этом один из ключевых факторов, используемых при прогнозировании пассажиропотока – потребление электроэнергии в Московской агломерации – можно будет предсказывать применяя методику, реализованную в подходе “Гусеница”-SSA. Этому вопросу посвящена следующая глава диссертации.

В **Главе 4** развивается методика для среднесрочного прогнозирования суточных объемов пассажирских перевозок Московским метрополитеном. Она включает три варианта прогноза: 1) на основе искусственных нейронных сетей: использовалась многослойная ИНС рекуррентного типа, на вход которой подавался набор факторов, влияющих на суточный объем пассажирских перевозок; 2) используя сингулярно-спектральный анализ, реализованный в пакете “Гусеница”-SSA: в этом случае анализировались только данные временного ряда суточных перевозок пассажиров; 3) совместное использование ИНС и подхода -

“Гусеница”-SSA: на вход ИНС, в дополнение к указанным выше факторам, подавались данные прогноза, вычисленные с помощью пакета “Гусеница”-SSA.

При прогнозировании на основе ИНС, из рассмотренного в главе 2 набора факторов использовались следующие: Var1 (год наблюдения), Var2 (месяц), Var3 (день недели), Var4 (тип дня), Var5 (отклонение дневной температуры от нормы) и Var6 (суточное потребление электрической энергии в Московской агломерации), полный перечень переменных представлен в Главе 2. Для данных переменных характерно то, что они обусловлены сезонностью объемов перевозок пассажиров в метро; по ним можно получить прогнозные значения применяя альтернативные методы получения информации; у этих переменных нет явления мультиколлинеарности (между ними нет сильной линейной зависимости).

Архитектура ИНС была взята следующей: 7 входных нейронов, два скрытых слоя, содержащих соответственно 16 и 8 нейронов, и один выходной нейрон. Входные данные были нормированы и приведены к диапазону  $[-1; +1]$ . Горизонт прогноза был выбран 30 и 50 рабочих дней наблюдения. После проведения серии экспериментов был определен оптимальный метод обучения Fletcher-Reeves. После проведения серии экспериментов был определен оптимальный метод обучения Fletcher-Reeves.

После завершения процедуры обучения ИНС проводилось тестирование обученной сети – оценка качества прогнозирования. На этом этапе в качестве переменной Var7 на вход ИНС подавалось то значение, которое выдавалось сетью в качестве прогноза на предыдущем шаге вычислений.

Результаты экспериментов показали, что относительная ошибка симметрична относительно нуля и не превышает 3 и 5% . Таким образом, используя ИНС, можно с хорошей точностью прогнозировать изменения объемов перевозок пассажиров метрополитеном.

Второй метод, который рассматривается в этой главе, заключался в сингулярно-спектральном анализе исследуемого временного ряда. В качестве исходной информации использовался отфильтрованный вейвлетами временной ряд (оставлено 256 коэффициентов из 1024). Исход-

ный ряд был стандартизирован средствами программы CaterpillarSSA (version 3.40, Professional Edition). Для прогнозирования пассажирских перевозок на основе сингулярно-спектрального анализа использовалась методика и последовательность вычислений, изложенная в главе 3. На начальном этапе выполнено преобразование временного ряда, описывающего суточный пассажиропоток в метрополитене в траекторную матрицу [44, 45]. Далее проводилось сингулярное разложение этой матрицы, анализ результатов ее разложения с помощью метода главных компонент и отбор тех компонентов, которые могут представлять интерес для исследователя. При этом (несмотря на проведенную ранее вейвлет-фильтрацию исходного ряда) дополнительно отбрасывались компоненты, ответственные за высокочастотную составляющую анализируемого временного ряда. Результаты анализа показали, что рассматриваемые компоненты отвечают за трендовую и периодические (сезонные) составляющие анализируемого ряда.

На заключительной стадии проводилась реконструкция одномерного временного ряда на основе отобранных компонентов. При реконструкции ряда использовалось 13 главных компонент, их общий вклад составил почти 99,91%. Было выявлено, что отбрасываемые компоненты неплохо согласуются с нормальным распределением, из чего можно предположить, что отвечающий им процесс по своему поведению близок к гауссовскому шуму.

После выполнения этапов анализа (вложение, сингулярное разложение, группировка, диагональное усреднение) были получены прогнозные значения на 30 и 50 дней, которые были сопоставлены с исходными данными и результатами прогноза, полученными с помощью ИНС. Таким образом, метод SSA позволил проводить среднесрочный прогноз с приемлемой точностью, при этом метод хорошо предсказывает трендовую и сезонную составляющую исследуемого временного ряда.

Было проведено сопоставление и анализ сравнения результатов прогноза с помощью ИНС и SSA, тем самым была также проведена проверка изменений качества прогноза при последовательном исключении переменных выступающих в качестве влияющих факторов на исследуемый временной ряд (например, таких как отклонение дневной

температуры от нормы) и (суточное потребление электрической энергии). Была также проведена дополнительная работа по оценке точности прогноза при совместном использовании методов ИНС и SSA: прогноз SSA выступал в качестве «подсказки» для ИНС, в виде дополнительного нейрона на входе ИНС.

Таким образом, наилучшего варианта прогноза удалось добиться с помощью ИНС. При этом из перечня факторов, подаваемых на вход ИНС, можно исключить отклонения дневной температуры от среднестатистической нормы (переменная Var5). Данный фактор не оказывает заметного влияния на результаты прогноза. Прогноз методом SSA оказался смещенным относительно прогнозируемых данных в область больших значений пассажиропотока. Это же явилось причиной смещения прогнозных значений в область больших величин пассажиропотока при совместном использовании методов ИНС и SSA.

В **Заключении** подводятся итоги выполненных исследований, дается краткое описание работ, положенных в основу диссертации, формулируются основные результаты и личный вклад соискателя в проведенные исследования.

#### **На защиту выносятся следующие результаты:**

1. Методологический подход к построению математической модели прогнозирования изменений объемов пассажирских перевозок, основанный на использовании в качестве исходных данных временных рядов динамики объема пассажирских перевозок и ключевых факторов, на него влияющих, в том числе, энергопотребления, как показателя социальной и экономической активности населения в рассматриваемом регионе или агломерации.
2. Ключевые факторы, влияющие на изменение суточных объемов перевозок, информация по которым на этапе прогнозирования либо известна, или же может быть предсказана с использованием математических методов прогнозирования (к такому фактору, в том числе, относятся данные об энергопотреблении в рассматриваемом регионе).

3. Математические модели, методы и алгоритмы среднесрочного прогнозирования суточных объемов потребления электрической энергии и пассажирских перевозок в Московском метрополитене.
4. Вычислительные алгоритмы для сформированной математической модели, основанные на применении искусственных нейронных сетей и сингулярно-спектрального анализа при прогнозировании суточных объемов пассажирских перевозок Московским метрополитеном в зависимости от суточного потребления электрической энергии в Московской агломерации.



# **1 Анализ применяемых на практике методов и подходов для определения, оценки изменений и прогнозирования пассажирских перевозок**

Прогнозирование пассажирских перевозок является актуальной задачей, как в академической, так и в прикладной среде во всём мире. Изменение величины пассажирских перевозок характеризуется спросом на транспортные услуги. Прогнозирование спроса на транспортные услуги в современной практике осуществляется с применением различных теоретических подходов: мультипликативный, распределением ценности времени пассажира, гравитационная модель индуцированного спроса. Рассмотрим вопросы возможности и ограничения применения подходов некоторых прикладных исследований и моделей по прогнозированию спроса пассажиров на транспортные услуги.

С позиции теории больших систем описание и регулирование процессов в таких системах с помощью одного измеримого количественного показателя означает сведение всего сложного многомерного явления к одномерной модели. Одномерная модель для любого вида транспорта не в состоянии адекватно отразить сложные многомерные и динамические процессы и взаимосвязи системы. Необходимо при разработке модели прогнозирования объемов пассажирских перевозок и транспортного спроса (как и для других систем жизнеобеспечения) определять и использовать целый набор взаимосвязанных измеримых показателей.

## **1.1 Существующая структура показателей измерения и характеристик транспортного спроса**

Одним из главных требований общества является удовлетворение его потребностей, в том числе – потребности в передвижении. В связи с этим, можно предположить, что каждый пассажир, выбирая тот или иной вид транспорта, стремится максимизировать полезный эффект потребления благ (услуг транспорта). Пассажиры, преследуя указанную цель, формируют спрос на места в различных типах транспортных средств, удовлетворение которой является главной задачей деятельности транспортной системы. Для передвижения из одного пункта

в другой пассажир может воспользоваться различными видами транспорта.

В зависимости от цели поездки и критериев, которыми задаётся пассажир, при выборе того или иного вида транспорта, эти критерии могут быть различными. Таким образом, проблема индивидуального выбора вида транспортного средства пассажиром заключается в решении вопроса о том, каким количеством поездок различными видами или типами транспорта пассажир может воспользоваться при заданных значениях критериев и ограничениях, накладываемых на них.

В этой связи, в прикладной науке возникает необходимость в создании математических моделей, которые должна объяснить, как определяется выбор типа и вида пассажирского транспорта пассажиром, учитывая, что каждый пассажир среди множества доступных ему видов и типов транспортных средств делает оптимальный выбор.

Потребности пассажиров на транспортные услуги могут быть описаны следующими показателями: скоростью (сообщения, перемещения) или временем поездки, безопасностью, удобством (комфортом, показателем транспортной усталости), стоимостью поездки (перевозки).

Показатели скорости, безопасности и удобства в явном виде не могут иметь адекватного денежного определения. Они могут иметь только физически измеримое выражение, что определяется требованием адекватности описания транспортной системы [46].

Транспортный спрос в городах и регионах возникает в силу того, что весь комплекс основных социально-значимых видов деятельности, не может осуществляться в одной географической точке. Например, территория города делится на спальные, промышленные, офисные районы, культурно-исторический центр, районы с большим количеством торговых площадей. Каждая из таких территорий создаёт и притягивает к себе транспортные потоки с определёнными целями.

В настоящее время спрос пассажиров на транспортные услуги характеризуется объёмными, качественными, экономическими и конкурентными показателями.

1) *Объёмные показатели* – количество пассажиров, осуществляющих поездки, расстояния поездок, процент использования производ-

ственных мощностей.

Количество пассажиров, перевезённых на конкретном маршруте может быть записано в виде:

$$Q = \sum q_j, \quad (1)$$

где  $q_j$  - количество пассажиров, перевезённых между всеми остановочными пунктами, входящими в маршрут,  $j$ -тым видом транспорта,  $j=1 \div n$  (вид транспорта: железнодорожный, автомобильный и т.д).

Следует отметить, что расстояние поездки является ортодромическим ( кратчайшая линия между двумя точками на поверхности вращения) для воздушного транспорта, и фактическим для железнодорожного и автомобильного транспорта.

Процент использования производственной мощности (вместимости) транспортного средства (статический показатель) можно оценить как:

$$\alpha_{pass} = Q_{pass}/Q_{mest}, \quad (2)$$

где  $Q_{pass}$  - количество перевезённых пассажиров в одном транспортном средстве (вагон или поезд, воздушное судно, автобус),  $Q_{mest}$  - количество мест в одном транспортном средстве (вагон или поезд, воздушное судно, автобус).

Процент использования производственной мощности (вместимости) транспортного средства (динамический показатель) определяется как:

$$\alpha_{pass*km} = QL_{pass*km}/Q_{mest*km}, \quad (3)$$

где  $QL_{pass*km}$  - количество пассажиро\*километров в одном транспортном средстве (вагон или поезд, воздушное судно, автобус),  $Q_{mest*km}$  - количество место\*километров в одном транспортном средстве (вагон или поезд, воздушное судно, автобус).

Объёмные показатели позволяют количественно оценить состояние потребительского спроса на пассажирские перевозки.

2) *Качественные показатели* – это относительные величины, выражающие соотношение между количественными показателями такие как: общая продолжительность поездки, удобство времени отправления и прибытия, основные и дополнительные условия поездки. Оценку качественных показателей на разных видах транспорта различны-

ми авторами предлагается проводить методом парных сравнений и с применением коэффициентов значимости. Метод парных сравнений по каждому качественному показателю позволяет определить наиболее эффективный вид транспорта, обслуживающий маршрут, и ранжировать их по мере убывания (например):

$$\gamma_2 < \gamma_1 < \gamma_3, \quad (4)$$

где 1, 2 и 3 – сравниваемые виды транспорта на маршруте. Для самого лучшего вида транспорта по конкретному качественному показателю присваивается значение 3, для худшего – 1, для среднего – 2.

Для всех качественных показателей устанавливаются коэффициенты значимости, составляющие в сумме 1:

$$\beta_1 + \beta_2 + \beta_3 + \beta_4 = 1. \quad (5)$$

Набор качественных показателей позволяет дать количественную характеристику качества транспортного обслуживания населения на маршруте, выявить конкурентные преимущества и сферы рационального применения разных видов транспорта, оценить соответствие качественных показателей стандартам транспортного обслуживания населения.

3) *Экономические показатели*: общая стоимость поездки, себестоимость поездки. Анализ тарифов должен проводиться для разных периодов года (высокие и низкие периоды тарифов). При оценке себестоимости перевозок и расходов на межрегиональные пассажирские перевозки по маршрутам должны быть применены современные методические подходы к управлению издержками на разных видах транспорта.

4) *Состояние конкуренции*: показатели состояния транспортного рынка учитывают перечень видов транспорта и перевозчиков, осуществляющих регулярные пассажирские перевозки по маршруту (корреспонденции), количество назначений и производственную мощность перевозчиков, характеристику конкуренции.

Набор данных показателей позволяет получить объективную характеристику транспортного предложения на маршрутах. Для оценки конкурентного состояния рынка могут применяться показатели рыночной концентрации и индекс Герфиндаля–Гиршмана [47].

Коэффициент концентрации позволяет сопоставить доли предприятий, влияющих на рыночную долю отрасли на транспортном рынке пассажирских перевозок. Коэффициент концентрации определяется как сумма рыночных долей крупнейших перевозчиков:

$$CR_k = \sum_{i=1}^k S_i, \quad (6)$$

где  $CR_k$  - индекс концентрации  $k$  перевозчиков, в %;  $S_i$  - доля продаж  $i$ -го перевозчика в объёме реализации транспортных услуг на рынке, в %;  $k$  - число хозяйствующих субъектов (перевозчиков) на рынке, взятых для расчёта индекса Индекс Герфиндаля—Гиршмана (обозначаемого  $HHI$ ).

Индекс Герфиндаля—Гиршмана используется для оценки степени монополизации отрасли, вычисляется как сумма квадратов долей продаж каждого перевозчика в отрасли [47]:

$$HHI = S_1^2 + S_2^2 + \dots + S_n^2, \quad (7)$$

где  $S_1, \dots, S_n$  - выраженные в процентах доли продаж компании – перевозчика в отрасли, определяемые как отношение объёма продаж перевозчика к объёму всех продаж отрасли. По значениям коэффициентов концентрации (CR) и индексов Герфиндаля – Гиршмана выделяются три типа рынка см. Таблица 1.1.

## 1.2 Методологии оценки изменений транспортного спроса

### 1.2.1 Основные этапы прогнозирования изменений транспортного спроса

В ходе задачи оценки транспортного спроса моделированию подлежит изменение спроса конкретный вид транспорта, оценку которого можно разбить на следующие направления:

1. Динамика показателей спроса на транспортные услуги за счёт изменения транспортной подвижности населения.
2. Динамика спроса на пассажирские перевозки, за счёт изменений транспортной инфраструктуры (индуцированный спрос).
3. Изменение спроса на пассажирские перевозки на конкретный вид транспорта из-за переключений с других видов транспорта:

Высоко концентрированные рынки	При $70\% < CR_3 < 100\%$ $2000 < HHI < 10\ 000$	При $80\% < CR_4 < 100\%$ $1800 < HHI < 10\ 000$
Умеренно концентрированные рынки	При $45\% < CR_3 < 70\%$ $1000 < HHI < 2000$	При $45\% < CR_4 < 80\%$ $1000 < HHI < 1800$
Низко концентрированные рынки	При $CR_3 < 45\%$ $HHI < 1000$	При $CR_4 < 45\%$ $HHI < 1000$

Таблица 1: Уровни конкуренция на рынках транспортных услуг для пассажиров

- Переключение с других видов транспорта по причине роста доходов населения или субъективных предпочтений пассажиров.

- Переключение с других видов транспорта за счёт изменения параметров этих видов транспорта (например, изменения времени в пути, стоимости, комфортабельности поездок).

Разделение моделей оценки изменений транспортного спроса на вышеуказанные направления позволяет учитывать различные факторы, влияющие на прирост спроса на транспортные услуги, что не может быть объединено в одной модели.

Для моделирования и оценки спроса на транспортные услуги по первому направлению может быть использована многофакторная линейная регрессионная модель. Такой выбор обусловлен связью подвижности населения с социально - экономическими факторами и тем, что данный класс моделей хорошо подходит для целостных транспортных систем. Также стоит отметить, что модель рассчитывается в разностях (то есть для приростов) для учёта возможных проблем, связанных с нестационарностью временных рядов, вероятностные свойства кото-

рых изменяются с течением времени.

### 1.2.2 Изменение спроса на транспортные услуги за счёт изменения транспортной подвижности населения

Одним из основных показателей транспортного спроса является транспортная подвижность. Под транспортной подвижностью населения понимается количество поездок на одного человека или количество пассажиро-километров на одного человека в год и может определяться по транспорту в целом, по видам транспорта общего пользования.

Различают два основных вида показателя «транспортной подвижности»: *статический* - количество поездок, приходящихся на 1 человека в год, и *динамический* - пассажирооборот (ПКМ), приходящийся на одного человека в год.

Статическая транспортная подвижность населения определяется по формуле:

$$TP_c = \frac{V}{M}, \quad (8)$$

где  $V$  – количество перевозки пассажиров в целом по транспортному комплексу, пасс,  $M$  – численность населения.

Динамическая транспортная подвижность населения  $TP_d$  определяется по формуле:

$$TP_d = \frac{VL}{M}, \quad (9)$$

где  $VL$  – пассажирооборот, пасс.км.

В настоящее время в открытом доступе публикуются статистические сборники – «Российский статистический ежегодник», «Россия в цифрах» и «Демографический ежегодник России», отражающие показатели численности населения России и перевозок пассажиров по видам транспорта.

Динамическая транспортная подвижность населения показывает изменения мобильности населения при перевозках на большое расстояние. Статическая транспортная подвижность отражают частоту поездок, что наиболее актуально при небольших и средних дальностях поездок.

Динамика показателей транспортной подвижности отражает изменение пассажирских перевозок в стране, уровень материального бла-

госостояния людей и уровень материально-технической базы транспорта [48].

Среди основных факторов, влияющих на будущие подвижности (динамику подвижности) населения можно назвать следующие:

1. Общие показатели экономического развития: валовой региональный продукт (ВРП), оборот розничной торговли, инвестиции в основной капитал, обеспеченность населения личным автотранспортом.

2. Демографические показатели: численность населения, численность экономически активного населения, доля экономически активного населения.

3. Финансовые показатели: индексы тарифов по видам транспорта; среднедушевые доходы населения.

На перспективный расчётный срок изменения транспортной подвижности можно определять следующими методами: на основе результатов обработки отчетно - статистических данных — методом экстраполяции; по результатам натурного обследования пассажиропотоков; по результатам выборочных анкетных обследований; исходя из потребностей населения в передвижениях (аналитический метод).

Перечисленные методы прогнозирования транспортной подвижности населения имеют отдельные недостатки. Транспортная подвижность, рассчитанная на основании обработки отчетно - статистических данных или определённая по результатам натурного обследования пассажиропотоков, отражает маршрутную подвижность на период получения статистических данных. Она не учитывает перспективные изменения спроса на транспортные услуги при улучшении работы транспорта и росте благосостояния населения.

Транспортная подвижность, определённая на основании данных выборочного анкетного обследования, является сетевой. Однако данные такого обследования отражают подвижность только на период его проведения. Кроме того, транспортная подвижность, установленная по данным выборочного анкетного обследования, может иметь значительные погрешности из-за недостаточного процента выборки, неодинакового соотношения групп населения, попавших в выборку, времени проведения обследования и др.

Метод подсчета подвижности населения городов путем выявле-



ния потребностей в передвижениях базируется на ряде предположений и допущений. Сама потребность в передвижениях зависит от многих факторов, которые трудно поддаются учёту. Поэтому определённая таким путем подвижность всегда сравнивается с фактической подвижностью, делённой на коэффициент пересадочности, который изменяется в зависимости от величины населённого пункта (транспортного района).

Учитывая вышеизложенное, транспортную подвижность на перспективу рекомендуется прогнозировать по данным отчетно-статистических показателей, исходя из предельных значений подвижности в каждой группе населённых пунктов. Значение транспортной подвижности для определённого транспортного района принимается в границах между допустимыми пределами колебания этого показателя, с учетом изменений валового регионального продукта и индекса тарифа.

Для оценки чувствительности подвижности населения от вышеуказанных экономических и социальных факторов рассмотрим применение многофакторной линейной регрессионной модели.

Рассмотрим на примере получение коэффициентов чувствительности и прогнозных значений транспортной подвижности населения из транспортного района  $i$  в транспортный район  $j$  (на основании матрицы существующего транспортно спроса) от изменений валового регионального продукта (ВРП) и индекса тарифа. Для каждой корреспонденции по виду транспорта будет использоваться модель:

$$\Delta M_t = \beta_0 + \beta_1 \Delta GRP_t^{fr} + \beta_2 \Delta GRP_t^{to} + \beta_3 \Delta It_t + \Delta \varepsilon_t, \quad (10)$$

где  $\Delta M_t$  – изменение подвижности (пассажиропотока) из транспортного района  $i$  для конкретного вида транспорта в момент времени  $t$  по отношению к моменту  $t-1$ ;  $\Delta GRP_t^{fr}$  – изменение валового регионального продукта в транспортном районе, из которого идёт пассажиропоток, в момент времени  $t$  по отношению к моменту  $t-1$ ;  $\Delta GRP_t^{to}$  – изменение валового регионального продукта (ВРП) в транспортном районе, в который идёт пассажиропоток, в момент времени  $t$  по отношению к моменту  $t-1$ ;  $\Delta It_t$  – изменение индекса тарифа для вида транспорта в момент времени  $t$  по отношению к моменту  $t-1$ ;  $\beta = (\beta_0, \beta_1, \beta_2, \beta_3)$ ,  $\varepsilon_t$  – случайная ошибка.

Чтобы получить оценки  $\hat{\beta} = (\beta_0, \beta_1, \beta_2, \beta_3)$ , необходимо:

1. Получить следующие данные: прирост пассажиропотока ( $\Delta M_t$ ) для конкретной корреспонденции по конкретному виду транспорта в виде вектора (обозначим его как  $Y$ ); факторы (в данном случае два прироста ВРП и индекса тарифа) и сформировать из них матрицу (обозначим её  $X$ ), в которой значения факторов расположены по столбцам.

2. Подставить описанные выше данные в выражение:

$$\hat{\beta} = (X^T X)^{-1} X^T Y. \quad (11)$$

Таким образом, можно получить оценки коэффициентов чувствительности. Для получения прогнозов пассажиропотока, помимо коэффициентов чувствительности (заданных экзогенно (предопределены, заданы их значения, независимости от функционирования моделируемой системы) или найденных как описано выше) также необходимы изменяемые значения факторов (в данном случае два прироста ВРП и индекса тарифа). Тогда подставив их в уравнение модели, описанное выше, находятся изменения приростов пассажиропотока на годы, по которым есть прогнозные значения факторов. Из приростов легко получить объёмы:

$$M_{t+1} = M_t + \Delta M_{t+1}, \quad (12)$$

где  $M_t$  - известный пассажиропоток за прошлый период (то есть такую процедуру стоит проводить, начиная с первого прогнозного значения, когда известен фактический пассажиропоток за последний год);  $\Delta M_{t+1}$  - получаемое значение прироста спроса на транспорт;  $M_{t+1}$  - прогнозное значение пассажиропотока.

В случае с трансграничными перевозками, к вышеперечисленным переменным добавляются факторы, связанные с международными социально - экономическими и финансовыми отношениями, например: валютные курсы; внешнеторговый оборот (как показатель уровня экономического сотрудничества); наличие визового режима; типологический характер связи (туристический, деловой, личный).

Получив оценки коэффициентов и имея доступ к прогнозным значениям для факторов модели, можно получить прогнозные значения для прироста подвижности и, следовательно, прогноз для компоненты прироста пассажиропотока, связанной с изменением в подвижности.

Отметим, что данная компонента по своей сути будет отражать ту часть прироста пассажиропотока, которая произошла за счёт переключения с другого вида транспорта без изменения параметров для видов транспорта.

Транспортная подвижность различается у разных групп населения. По социальному составу население обычно разделяют на четыре группы:

1) трудящиеся (рабочие и служащие) предприятий промышленности, организаций и сельского хозяйства;

2) трудящиеся (рабочие и служащие) учебных учреждений, предприятий жилищно-коммунального хозяйства, торговли, социально-бытовых услуг;

3) учащиеся вузов, техникумов и училищ;

4) несамодеятельное население: дети дошкольного и школьного возраста, неработающие пенсионеры, домохозяйки, инвалиды.

Наиболее высокая транспортная подвижность характерна для первой и третьей групп населения.

Транспортная подвижность имеет большие пределы колебания. Она изменяется в зависимости от величины населённого пункта, его обеспеченности местами приложения труда и социально-бытовыми услугами, уровня развития транспорта и других факторов.

В качестве обобщающего показателя при анализе транспортной подвижности можно также принять численность населения, проживающего в территориальном образовании, а влияние других факторов учитывают в допустимых пределах колебания этого показателя.

Транспортная подвижность не остаётся постоянной во времени. Она, как правило, повышается с ростом благосостояния населения, в связи с созданием новых мест приложения труда, улучшением работы пассажирского транспорта и повышением качества транспортной инфраструктуры.

Для организации эффективной работы пассажирского транспорта необходимо стремиться к наиболее точному определению объема не только текущего спроса, но и тенденцию его изменения в перспективе, так как от этого зависят потребность в транспортных средствах, а также в инвестициях, направленных на развитие пассажирского транс-

порта.

Наибольший уровень транспортной подвижности характерен для населения, проживающего в крупных городах и находящегося в трудоспособном возрасте – от 18 лет до 55-60 лет. Как правило, в населённых пунктах проживает около 50% населения, находящегося в трудоспособном возрасте.

В таблице 1.2.2 представлены нормативы транспортной подвижности городского и сельского населения, которые используются в градостроительном проектировании.

Группы городских округов и поселений, сельских населённых пунктов	Численность населения тыс.чел	Транспортная подвижность поездок/год на пассажирском транспорте общего пользования	Средняя транспортная подвижность поездок/год на пассажирском транспорте общего пользования	Средняя транспортная подвижность поездок/суток на пассажирском транспорте общего пользования
Группы городских округов и поселений				
крупнейшие	свыше 1000	650-820	700	1.92
крупные	от 250 до 1000	400-650	575	1.58
большие	от 100 до 250	300 - 400	450	1.23
средние	от 50 до 100	250-300	275	0.75
малые	от 20 до 50	150-250	200	0.55
малые	от 10 до 20	100-150	125	0.34
малые	от 3 до 10	80-100	90	0.25
Группы сельских населенных пунктов				
крупные	свыше 3	80-100	90	0.25
большие	от 1 до 3	60-80	70	0.20
средние	от 0.2 до 1	50-60	55	0.15
малые	до 0.2	30-50	40	0.10

Таблица 2: Нормативы транспортной подвижности населения




Рис. 1: Изменение средней транспортной подвижности в зависимости от численности населения

Из данных таблицы 1.2.2 и рис. 1 следует чёткая зависимость: уменьшения транспортной подвижности при снижении численности населения. В сельских населённых пунктах, в отличие от городов, удельный вес передвижений пешком составляет около 60% , причем максимальная величина достигается в рабочие дни. За последние годы, с ростом уровня автомобилизации и строительством коттеджных посёлков, основным способом передвижений жителей сельских населённых пунктов стал легковой автотранспорт (служебный или находящийся в личной собственности граждан), на нем в будние дни совершается 25 - 30% поездок, а в выходные дни – до 40% . Доля пассажирского транспорта общего пользования составляет 5 - 10% от общего числа передвижений, чуть ниже доля передвижений с использованием велосипеда – 4 - 6% . Такая структура передвижений принципиально отличается от соответствующей структуры в крупных городах. Данные исследования показали, что в сельских населённых пунктах из общего количества передвижений в сутки, равного 3, доля поездок с использованием общественного пассажирского транспорта не превы-

шает 5 - 10%. Это свидетельствует о том, что в связи с незначительным количеством рейсов общественного транспорта население сельских населённых пунктов вынуждено искать другие способы передвижения.

### 1.2.3 Изменение спроса на транспортные услуги для пассажиров за счёт индуцированного спроса, связанного с изменением транспортной инфраструктуры

В модели изменения спроса на транспортные услуги для пассажиров за счёт индуцированного спроса, связанного с изменением транспортной инфраструктуры предполагается, что спрос на транспортные услуги ограничивает недостаточный уровень инфраструктурной связности. Для оценки изменения транспортного спроса предлагается использовать гравитационную модель (подробнее см. например [49], [50], [51], [52], [53], [54]) следующего типа:

$$\Delta PT_{ij} = A_{ts} \frac{P_i P_j}{ts_{ij}^2} - PT'_{ij}, \quad (13)$$

где  $\Delta PT_{ij}$  – прирост пассажиропотока из транспортного района  $i$  в транспортный район  $j$ ;  $P_i$  – численность населения транспортного района, из которого идёт пассажиропоток;  $P_j$  – численность населения транспортного района, в который идёт пассажиропоток;  $ts_{ij}^2$  – средневзвешенное время в пути между транспортными районами  $i$  и  $j$  (мера удалённости);  $A_{ts}$  – коэффициент, определённый на основании обучающей группировки «насыщенных» инфраструктурой пар пунктов, аналогичных паре транспортных районов  $i$  и  $j$  по удалённости  $ts$ , определён как средневзвешенный по объёму пассажиропотока коэффициент.  $PT'_{ij}$  – фактический пассажиропоток из транспортного района  $i$  в транспортный район  $j$  в условиях «ненасыщенной» транспортной инфраструктуры.

Следует отметить, что изменения транспортного спроса будет иметь положительное изменение, если планируется улучшение транспортной инфраструктуры по конкретной корреспонденции (для конкретного вида транспорта), в противном случае, прирост по данной компоненте равен нулю или отрицательный (в случае ухудшения транспортной инфраструктуры, снижения ее пропускной способности).

#### 1.2.4 Изменение спроса на транспортные услуги за счёт перераспределения пассажиров между видами транспорта

Рассмотрим изменение спроса на транспортные услуги за счёт переключения с другого вида транспорта из-за изменения параметров вида транспорта. Параметрами транспорта будем считать среднее время в пути, стоимость поездки и уровень комфорта. Тогда для каждого из рассматриваемых нами видов транспорта строится модель дискретного выбора между, двумя или более альтернативами. Среди факторов модели находятся параметры для аналогичных видов транспорта. Это связано с тем, что при выборе вида транспорта пассажиры учитывают параметры не только выбираемого вида транспорта, но и его аналогов. Говоря о точной форме модели дискретного выбора, то это либо *logit* модель (см. например [55], [56], [57]) либо *probit* модель (см., например, [59], [60]). Выбор осуществляется после получения оценок путём сравнения информационных критериев Акайке (*AIC*) [56], Шварца (*BIC*) [59], а также сравнением значений логарифма правдоподобия альтернативных вариантов.

Модель *logit* выглядит следующим образом:

$$P(y = 1|x) = f(z) = \frac{1}{1 + e^{-z}}, \quad (14)$$

где  $y$  – выбор пассажира (1, если выбирается данный вид транспорта и 0, если нет);  $x$  – вектор факторов;  $f(z)$  – функция плотности вероятности логистического распределения.

Модель *probit* имеет следующий вид:

$$P(y = 1|x) = \Phi(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}, \quad (15)$$

где  $y$  – выбор пассажира;  $x$  – вектор факторов;  $\Phi(z)$  – функция плотности вероятности нормального распределения.

Модели *logit* и *probit* во многом схожи и в обоих случаях  $z$  является «латентной» (скрытой) переменной - склонностью к выбору данного вида транспорта (для которого оценивается модель). Данная переменная представляет собой линейную комбинацию параметров транспорта:

$$z_i = \sum_{l=1}^s \alpha_l t_l + \sum_{j=1}^s \beta_j \rho_j + \sum_{k=1}^s \gamma_k c_k, \quad (16)$$

где  $t_l$  – среднее время в пути  $l$ -ого транспорта;  $\rho_j$  - стоимость поездки  $j$ -ого транспорта;  $c_k$  - уровень комфорта поездки  $k$ -ого транспорта.

Далее используются оценки коэффициентов модели  $(\alpha, \beta, \gamma, \rho)$  методом максимального правдоподобия [58]. Данные оценки обладают свойством состоятельности. Чтобы прогнозировать переключение с одного вида транспорта на другой, для каждой из моделей (по видам транспорта) рассчитываются предельные эффекты изменений транспортного спроса. Расчёт предельного эффекта происходит в конкретной точке корреспонденции пассажиров (отправления или назначения), следовательно, для прогноза переключений в конкретной корреспонденции предельный эффект будет рассчитываться при параметрах видов транспорта для этой корреспонденции. Для России в целом предельный эффект может быть рассчитан при усреднённых параметрах видов транспорта.

При оценке изменений использование модели описывающей изменение транспортного спроса с большим числом объясняющих переменных связан с тем, что другие модели (например, система нескольких одновременных *probit* уравнений *muprobit*) являются неприменимыми в силу высокой алгоритмической и вычислительной сложности.

Возможность улучшить данную модель может появиться, когда у данных появится панельная структура (это прослеженные во времени пространственные выборки, то есть они состоят из наблюдений одних и тех же экономических единиц, которые осуществляются в последовательные периоды времени, то есть у каждой корреспонденции будет несколько наблюдений во времени. В таком случае можно использовать панельные модели дискретного выбора: панельный *logit* или панельный *probit*.

Для простоты можно оценивать только *logit* модель, так как отличие её результатов от результатов *probit* модели незначительно.

Для получения данных о переключении для корреспонденции (точка отправления - точка назначения) при оценке по данным за последний год необходимо следующее:

1. Получить следующие данные:

Информацию о выборе пассажиром вида транспорта (распределение пассажиров по используемым видам транспорта) в виде вектора.



Значения параметров видов транспорта (обозначим их как  $x_i$ ).

Выбор пользователя корреспонденции (то есть точка, в которой значения параметров видов транспорта соответствуют актуальным для выбранной корреспонденции).

Указание пользователем изменения параметров видов транспорта.

2. Записать функцию правдоподобия для каждого рассматриваемого вида транспорта:

$$L(\beta) = \prod_{i=1}^n F(\beta_0 + \sum_i \beta_i x_i) \rightarrow \max_{\beta}, \quad (17)$$

где  $L(\beta)$  – функция правдоподобия;  $F(\cdot)$  – кумулятивная функция распределения логистического распределения в случае *logit*;  $x_i$  – параметры для видов транспорта: исследуемого и его аналогов. Набор видов транспорта для кластера задаётся вручную:  $\beta = (\beta_0, \beta_1, \dots)$  – оцениваемые коэффициенты.

3. Подставить в формулу (17) исходные данные (выбор и параметры видов транспорта) и численно найти глобальный максимум (есть множество методов, например, градиентный спуск) функции правдоподобия по оцениваемым коэффициентам  $\beta$ . В результате найдутся оценки  $\hat{\beta}$ .

4. Для получения изменений по переключению между видами транспорта для указанной корреспонденции, необходимо подставить актуальные значения параметров видов транспорта (для соответствующей корреспонденции), оценки  $\hat{\beta}$  в следующие уравнения (по каждому рассматриваемому виду транспорта для каждого параметра вида транспорта):

$$\frac{\delta y_i}{\delta x_k} = f(\beta_0 + \sum_i \beta_i \bar{x}_i) \hat{\beta}_k, \quad (18)$$

где  $\bar{x}_i$  – значения параметров видов транспорта для корреспонденции указанной пользователем;  $f$  – функция плотности вероятности логистического распределения;  $\hat{\beta}_k$  – оценка коэффициента, полученная выше для соответствующего параметра вида транспорта.

Особенностью таких предельных эффектов является то, что на эффект одного параметра видов транспорта будут влиять значения всех остальных параметров, так как они входят в функцию плотности

вероятности распределения. Благодаря этому, для расчёта показателей чувствительности к параметрам видов транспорта для конкретной корреспонденции, достаточно при расчёте предельных эффектов выбрать значения параметров видов транспорта равными соответствующим актуальным параметрам видов транспорта по необходимой корреспонденции.

Ключевым фактором при принятии решения о выборе вида транспорта являются совокупные затраты на поездку, состоящие из стоимости билета и стоимости потраченного времени, которые могут быть выражены формулой:

$$C_g = C + h, \quad (19)$$

где  $C$  – стоимость билета,  $h$  – стоимость потраченного времени,  $C_g$  – совокупные транспортные затраты.

Соотношение спроса на вид транспорта  $n$  и на вид транспорта  $m$  равно соотношению совокупных затрат:

$$\frac{P_n}{P_m} = \frac{C_{g-n}}{C_{g-m}} = q, \quad (20)$$

где  $P_n$  – пассажиропоток на виде транспорта  $n$ ,  $P_m$  – пассажиропоток на виде транспорта  $m$ ,  $C_{g-n}$  – совокупные затраты одного пассажира на виде транспорта  $n$ ,  $C_{g-m}$  – совокупные затраты одного пассажира на виде транспорта  $m$ .

Следовательно, доля пассажиров, переключившихся на вид транспорта  $n$  с транспорта  $m$  будет равна:

$$P_n = \frac{q}{q + 1}, \quad (21)$$

где  $q$  – соотношение совокупных затрат на видах транспорта  $m$  и  $n$ .

Из рис. 2 видно, что распределение поездок по видам транспорта будет осуществляться следующим образом:

а) на дальние расстояния (более 1000-1500 км) формируется спрос на маршруты воздушного сообщения, так как автомобильный и железнодорожный транспорт в значительной степени уступают авиационному транспорту по временным показателям;

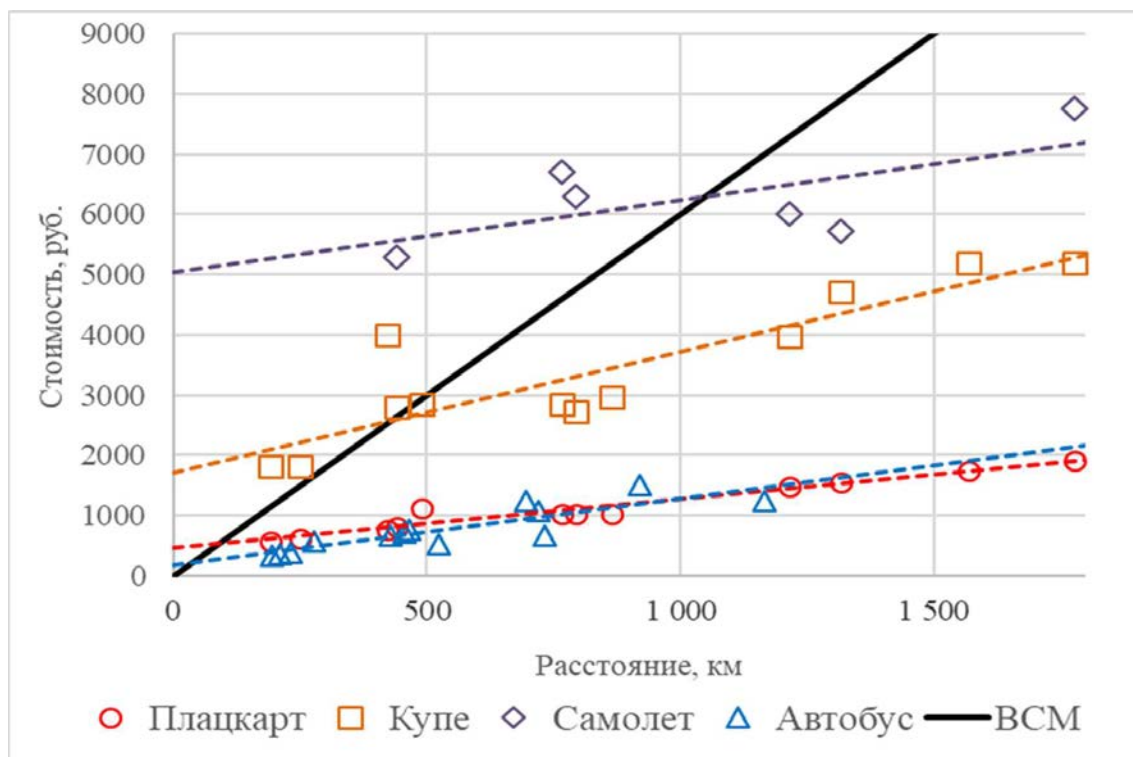


Рис. 2: Зависимость стоимости поездки от расстояния по видам транспорта (в ценах 2014 года)

б) на средние расстояния (600 – 1500 км) формируется спрос как на железнодорожный, так и на авиационный транспорт;

в) на сравнительно небольшие расстояния (до 400 - 600 км) формируется спрос на автомобильные перевозки, что обусловлено недостаточным уровнем комфорта при более продолжительных поездках, а также большими затратами времени.

Расчёт реального времени (рис. 3) складывается из: времени полёта с учетом руления; времени прохождения регистрации и посадки на рейс в аэропорту отправления (2 часа); времени получения багажа в аэропорту прибытия (0,5 часа); времени в пути от центра города отправления до аэропорта; времени в пути от аэропорта прибытия до центра города.

Существующие модели прогнозирования потребностей пассажиров в транспортных услугах учитывают, что чем больше разница в тарифах между видами транспорта, тем больше должно быть влияние цены на переключение пассажиропотока. При этом зависимость

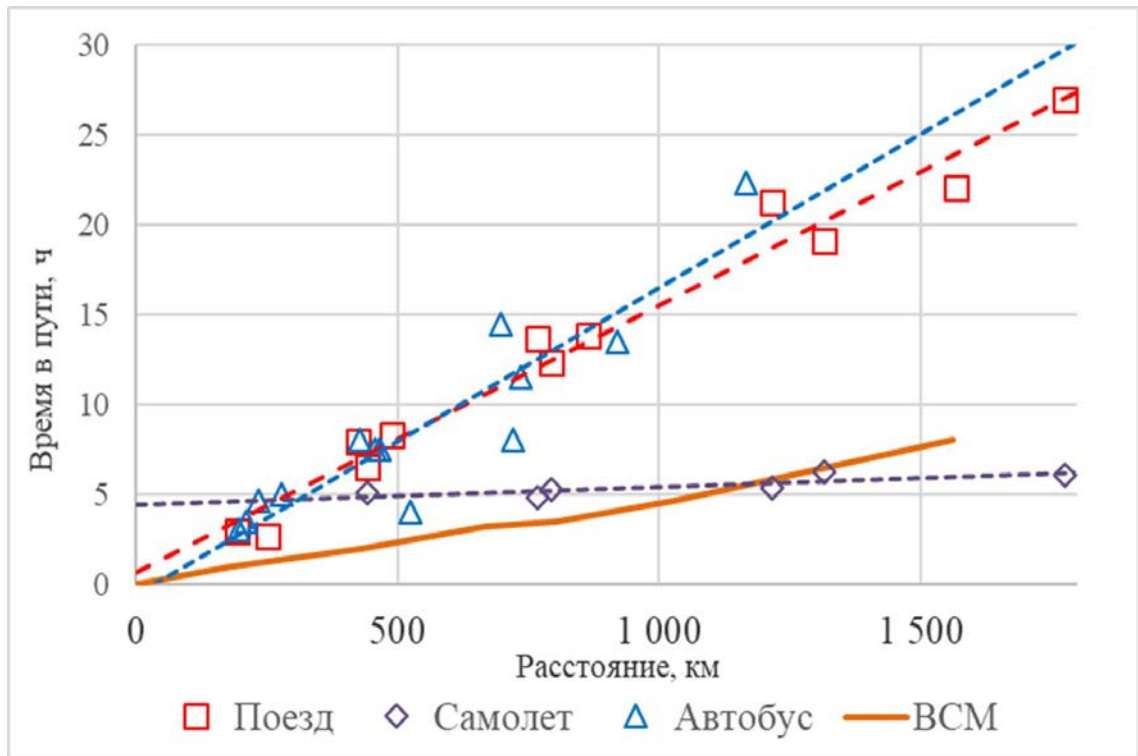


Рис. 3: Зависимость времени в пути от расстояния по видам транспорта

переключений от цены на билет должна быть нелинейной. Коэффициент эластичности может быть выражен следующим образом:

$$\alpha = \frac{C_n}{C_m}. \quad (22)$$

Смысл такого выражения заключается в том, что по мере увеличения дальности поездки растёт роль фактора цены поездки, что, в свою очередь, сокращает переключения. Дополнительным фактором, определяющим нелинейность зависимости переключений пассажиропотока от совокупных затрат на поездку является эластичность по комфортности поездки. Чем больше разница в комфорте между видами транспорта, тем больше значимость слагаемого  $h$  (стоимости времени в пути) в выражении (19) [121]. При этом коэффициент  $\beta$  состоит из трёх количественно измеримых критериев комфорта поездки:  $a$  – нормативная плотность размещения пассажиров в салоне (чел./м<sup>2</sup>),  $b$  – шумовое загрязнение в салоне (дБ),  $c$  – пунктуальность (%), рассчитываемая как среднее приращение продолжительности поездки.

Интегральную оценку комфорта можно рассчитать как среднее

значение нормированных показателей: плотности пассажиров, уровня шума в салоне и пунктуальности:

$$\beta = \frac{1}{3}(a + b + c), \quad (23)$$

где  $a$  - плотность пассажиров,  $b$  - уровень шума в салоне,  $c$  - пунктуальность.

С учетом выражений (19)-(23) можно получить следующее уравнение для расчёта переключения пассажиропотока с видами транспорта  $m$  и  $n$ :

$$\frac{P_n}{P_m} = \frac{C_m^\alpha + (h_m T_m)^{\beta_m}}{C_n^\alpha + (h_n T_n)^{\beta_n}}, \quad (24)$$

где  $P_n$  - начальный пассажиропоток видом транспорта  $n$  между двумя населёнными пунктами  $i$  и  $j$ ;  $P_m$  - пассажиропоток между двумя населёнными пунктами  $i$  и  $j$  видом транспорта  $m$ ;  $C_n$  - стоимость проезда видом транспорта  $n$  между городами  $i$  и  $j$ ;  $C_m$  - стоимость проезда видом транспорта  $m$  между городами  $i$  и  $j$ ;  $T_n$  - время в пути видом транспорта  $n$  между городами  $i$  и  $j$ ;  $T_m$  - время в пути видом транспорта  $m$  между городами  $i$  и  $j$ ;  $h_m$  - стоимость времени пассажиров, выбирающих вид транспорта  $m$ ;  $h_n$  - стоимость времени пассажиров, выбирающих вид транспорта  $n$ ;  $\alpha$  - коэффициент эластичности по цене;  $\beta$  - коэффициент эластичности по комфорту.

Уравнение (24) может применяться отдельно для перераспределения спроса на пассажирские перевозки на различных видах транспорта.

### 1.3 Анализ теоретических аспектов современной методологии прогнозирования транспортного спроса

Рассмотрим вопросы о возможности и ограничениях применения методологий некоторых прикладных исследований по прогнозированию спроса пассажиров на транспортные услуги. В работе Национальной компании французских железных дорог (*SNCF*), посвящённой моделированию введения железнодорожной магистрали, используются широко распространённые модели для прогнозирования спроса на транспортные услуги [61].

Применяемые *SNCF* модели прогнозирования спроса достаточно общие и могут быть применены для широкого класса задач. *SNCF* выделяет три ситуации в отношении введения нового вида сообщения:

1. Базовая ситуация – рассматриваются все годы, по которым доступна статистика.
2. Ситуация без проекта – рассматриваются годы, следующие за базовым годом и до момента введения нового участка.
3. Ситуация с проектом – рассматривается введение проекта в эксплуатацию и последующие за этим годы.

При этом выделяются следующие компоненты, по которым производится прогнозирование спроса на транспортные услуги:

1. Изменение спроса на транспортные услуги за счёт изменения социально-экономических переменных.
2. Изменение спроса на транспортные услуги вида транспорта за счёт переключения с другого вида транспорта.
3. Изменение индуцированного спроса на транспортные услуги.

Для моделирования спроса на пассажирские перевозки для конкретного вида транспорта  $M$  (сюда входят железнодорожный, воздушный, автомобильный, морской и речной) используется следующая мультипликативная модель:

$$Traffic(M)_t = K \cdot GDP_t^{gdp(M)} POP_t^{pop(M)} SUPPLY_t^{supply(M)}, \quad (25)$$

где,  $t$  – момент времени;  $K$  – константа модели;  $GDP$  – валовой национальный продукт (ВНП);  $POP$  – численность населения;  $SUPPLY$  – поставки (не конкретизируется это переменная);  $gdp(M)$ ,  $pop(M)$  и  $supply(M)$  – коэффициенты эластичности спроса на вид транспорта  $M$  по соответствующему показателю.

Переменные для модели берутся из государственной статистики, и осуществляется оценка коэффициентов эластичности спроса и констант модели. Оценивать такую нелинейную модель довольно сложно, поэтому для этого необходимо осуществить переход к модели в логарифмах:

$$\begin{aligned} \ln(Traffic(M))_t &= \ln(K) + gdp(M) \cdot \ln(GDP)_t + \\ &+ pop(M) \cdot \ln(POP)_t + supply(M) \cdot \ln(SUPPLY)_t + \varepsilon_t, \end{aligned} \quad (26)$$

где  $\varepsilon_t$  – случайная ошибка модели, являющаяся случайной величиной, распределенной по нормальному закону с математическим ожиданием равным нулю.

Оценки для константы и коэффициентов эластичности, можно получить с помощью метода наименьших квадратов. Более того, эти оценки будут эффективными в классе линейных несмещенных оценок, если выполнены предпосылки теоремы Гаусса-Маркова (подробнее см. [62], [63]), то есть: модель правильно специфицирована (функциональная форма модели соответствует функциональной форме данных, отсутствуют пропущенные и лишние переменные, линейность по параметрам), переменные не являются случайными величинами, отсутствует линейная зависимость между переменными, ошибки не носят систематического характера (математическое ожидание случайной ошибки равно нулю), дисперсия случайной ошибки постоянна, ошибки независимы.

Проблема состоит в том, что для прогноза (а именно так получают прогнозные значения для ситуации без проекта) понадобятся прогнозные значения регрессоров (ВВП, численности населения и поставок). Соответственно, точность прогноза спроса на услуги транспорта будет связана с точностью прогнозов используемых показателей. Избежать этого можно, используя для моделирования спроса на услуги транспорта подход Бокса-Дженкинса, то есть модели класса *ARIMA* (см. например [64], [65]).

Важную роль в анализе у SNCF играет показатель обобщённых издержек, который определяется следующим образом:

$$C_g = (P_{journey} + P_{access}) + h(T_{journey} + T_{access}). \quad (27)$$

где  $C_g$  – обобщённые издержки,  $P_{journey}$  – стоимость основной поездки,  $P_{access}$  – стоимость вспомогательных поездок (чтобы добраться до основного транспорта),  $T_{journey}$  – время основной поездки,  $T_{access}$  – время вспомогательных поездок,  $h$  – ценность времени.

Поскольку обобщённые издержки – это сумма денежных затрат и переведённых в денежный эквивалент временных затрат на поездку из зоны  $i$  в зону  $j$ , введя показатель суммарной стоимости поездки  $P = P_{journey} + P_{access}$  и суммарного времени поездки  $T = T_{journey} + T_{access}$ ,

можно представить выражение обобщённых издержек следующим образом:

$$C_g = P + hT, \quad (28)$$

Для моделирования прогноза переключения спроса по видам транспорта, при введении в эксплуатацию нового транспортного проекта или изменении параметров транспортного сообщения по существующей инфраструктуре, авторы используют два подхода. Первый подход ограничен выбором между двумя видами транспорта, в то время как второй лишён этого недостатка.

Первый подход связан с распределением ценности времени и значения ценности, при котором безразлично какой из двух видов транспорта использовать. То есть для каждого из двух видов транспорта (самолёт и поезд) у авторов подхода есть собственное выражение обобщённых издержек, так как стоимость и время поездки различны. Тогда найдётся такое значение ценности  $h_0$ , при котором без разницы какой транспорт использовать (то есть равны обобщённые издержки). Это значение находится явно:

$$h_0 = \frac{P_1 - P_2}{T_2 - T_1}. \quad (29)$$

Далее, находится доля пассажиров с ценностью времени  $h \leq h_0$  (то есть пользующихся тем транспортом, у которого на этом интервале ценности времени меньше обобщённых издержек), интегрированием функции плотности вероятности логнормального распределения по области  $h \in [0, h_0]$ , то есть нахождением вероятности, того что  $h \leq h_0$ :

$$Prob(h \leq h_0) = \int_0^{h_0} \frac{1}{\sigma h \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma^2}(\log(h) - m)^2\right) dh. \quad (30)$$

Доля пользующихся вторым видом транспорта ( $h \geq h_0$ ) находится вычитанием из единицы найденной выше доли, так как  $Prob(h > h_0) = 1 - Prob(h \leq h_0)$  по определению вероятности.

При изменении в параметрах транспортной системы, например, строится новая железнодорожная магистраль с точки зрения рассмат-



риваемой модели это изменение обобщённых издержек: стоимости и времени поездки.

Пусть изменяются параметры для первого вида транспорта, тогда меняются его обобщённые издержки, а, следовательно, точка пересечения меняется с  $h_0$  на некоторую новую точку  $h_1$ . Аналогично случаю с  $h_0$  находятся доли для двух видов транспорта для точки  $h_1$ . В результате, можно получить изменение долей использования каждого вида транспорта, то есть переключение с одного вида транспорта на другой.

Представленный подход имеет следующие недостатки: метод ограничен двумя видами транспорта и для случаев, где есть выбор из трёх и более видов транспорта он не подходит; метод использует логнормальное распределение доходов, а в соответствии с [64] распределение доходов имеет форму сочетаний логнормальных распределений. Такая модель прогноза учитывает только переключения, связанные с изменением стоимости и времени поездки, и не может учесть субъективные факторы.

Рассмотрим применение функции полезности поездки на транспорте  $m$  между городами  $i$  и  $j$  :

$$u_{ij}^m = e^{\gamma Cg_{ij}^m}, \quad (31)$$

где  $Cg_{ij}^m$  - обобщённые издержки поездки на транспорте  $m$  между зонами  $i$  и  $j$ ;  $\gamma$  - константа модели (фактор дисконтирования - является базой для расчётов издержек поездки с учётом фактора времени).

Для расчёта доли транспорта  $m$  среди всех остальных видов транспорта (всего  $M$  видов) используется следующая формула:

$$Share_{ij}^m = \frac{u(Cg_{ij}^m)}{\sum_{k \in M} u(Cg_{ij}^k)}. \quad (32)$$

Соответственно, при изменении параметров обобщённых издержек одного или нескольких видов транспорта, можно пересчитать их доли и получить изменения долей использования каждого вида транспорта. К плюсам такого подхода относится то, что число видов транспорта не ограничено двумя. Также использование функции полезности позволяет в некотором смысле учесть субъективные факторы.

Помимо переключений с другого вида транспорта, *SNCF* моделируют индуцированный спрос. Индуцированными поездками называются такие поездки, что их осуществление невозможно без проведения дополнительных мероприятий (например, улучшения инфраструктуры или повышения дохода). Следует отметить, что объём индуцированных или дедуцированных перевозок рассчитывается на основании поездок, возникших не в результате перераспределения между отдельными видами транспорта.

Для расчёта прогноза индуцированного спроса применяют гравитационную модель (оценка изменений с использованием данного метода рассмотрена в разделе 1.2.):

$$Traffic_{ij} = k \frac{((Pop_i \cdot Pop_j) \cdot (Rev_i \cdot Rev_j))^\alpha}{Cg_{ij}^\beta}, \quad (33)$$

где  $Pop_i, Pop_j$  – население в зонах  $i$  и  $j$ ;  $Rev_i, Rev_j$  – доходы населения в зонах  $i$  и  $j$ ;  $\alpha$  – коэффициент эластичности пассажиропотока по населению и доходам;  $\beta$  – коэффициент эластичности пассажиропотока по обобщённым издержкам;  $k$  – константа модели.

Взяв логарифмы от выражения (33) можно перейти к линейной модели:

$$\ln(Traffic_{ij}) = \ln(k) + \alpha \cdot \ln((Pop_i \cdot Pop_j) \cdot (Rev_i \cdot Rev_j)) - \beta \cdot \ln(Cg_{ij}) + \varepsilon, \quad (34)$$

С помощью метода наименьших квадратов можно получить оценки для константы модели и коэффициентов эластичности  $\alpha$  и  $\beta$ . При выполнении теоремы Гаусса-Маркова [63], эти оценки будут наилучшими в классе линейных несмещённых оценок.

Прогноз изменения в индуцированном спросе на транспортные услуги соотносится с изменением в обобщённых издержках следующим выражением:

$$\frac{\delta Traffic}{Traffic} = -\beta \frac{\delta Cg_{ij}}{Cg_{ij}}. \quad (35)$$

Гравитационные модели зарекомендовали себя как основной инструмент при моделировании прогнозов индуцированного спроса [66].

В модели используются социально-экономические, демографические и иные факторы, а также показатели, связанные с затратами на передвижение. Например, удалённость, время в пути или обобщённые издержки. Прогнозная модель представляет из себя уравнение:

$$PT_{ij} = k \frac{X_i^\alpha X_j^\beta}{c_{ij}^\gamma}, \quad (36)$$

где  $PT_{ij}$  - прогноз пассажиропотока из транспортного центра  $i$  в транспортный центр  $j$ ;  $X_i$  - транспортный центр, из которого идёт пассажиропоток;  $X_j$  - транспортный центр, в который идёт пассажиропоток;  $ij$  - показатель, связанный с затратами на передвижение,  $k$  - константа модели (коэффициент пропорциональности);  $\alpha, \beta, \gamma$  - коэффициенты, которые необходимо оценить. Одним из основных плюсов данного подхода является то, что линеаризация модели происходит с помощью логарифмирования (также вносится аддитивная случайная составляющая):

$$\ln(PT_{ij}) = \ln(k) + \alpha \ln(X_i) + \beta \ln(X_j) - \gamma \ln(c_{ij}) + \varepsilon_{ij}, \quad (37)$$

где  $\varepsilon_{ij}$  - случайная компонента.

В таком виде модель может быть оценена с помощью метода наименьших квадратов. Более того, полученные оценки будут эффективными в классе линейных несмещённых, если выполнено условие теоремы Гаусса-Маркова (математические ожидания оценок параметров равны их теоретическим значениям).

Другой подход к моделированию прогноза индуцированного спроса на транспортные услуги предлагают *Deutsche Bahn* в своей работе [67]. Индуцированный спрос на транспортные услуги рассчитывается по следующей формуле:

$$R_{ind} = \frac{GK_\alpha - GK_p}{\max(GK_\alpha, GK_p)} \min(R_p, R_a) \cdot AR, \quad (38)$$

где  $R_{ind}$  - индуцированные перевозки по видам транспорта и целям поездки;  $GK_p$  - прогноз обобщённых расходов;  $R_p$  - прогноз числа поездок;  $R_a$  - число поездок на момент проведения анализа или предше-

ствующего этапа прогнозирования;  $AR$  – доля обобщённых расходов в полных затратах на поездку.

В данном подходе прогноза учитывается определяемая в зависимости от цели поездки средняя доля обобщённых расходов на поездку в полных общих затратах на действия, связанные с осуществлением поездки. Таким образом, в расчёт принимается то, что, например, небольшое уменьшение продолжительности поездки не обязательно приведёт к соответствующему увеличению количества отпускных поездок, так как продолжительность отпуска существенно дольше времени, затрачиваемого на поездку к месту отдыха и обратно.

Рассмотрим иной подход к моделированию спроса на услуги транспортной системы на примере прогноза Департамента транспорта Великобритании для пассажирской авиации, приведенной в работе [68].

В этом подходе, для учёта неоднородности спроса на транспортные услуги, авторы выделяют сегменты по трём параметрам: гражданство пассажира, цель поездки, пункт назначения. В данной работе подход отличается тем, что используется только одна модель для прогнозирования изменения спроса на пассажирские перевозки:

$$\Delta \ln(Q_{it}) = \alpha_i + \beta_i \Delta \ln(Z_{it}) + \gamma_i \ln(Q_{it-1}) + \delta_i \ln(Z_{it-1}) + \varepsilon_{it}, \quad (39)$$

, где  $Q_{it}$  – число пассажиров в сегменте  $i$  в момент времени  $t$ ;  $Z_{it}$  – характеризующие переменные для сегмента  $i$  в момент времени  $t$  (ВВП, импорт, экспорт, тарифы и другие социально-экономические переменные);  $\varepsilon_{it}$  – случайная составляющая модели;  $\alpha_i, \beta_i, \gamma_i, \delta_i$  – оцениваемые коэффициенты.

К минусам такого подхода стоит отнести невозможность моделирования индуцированного спроса; для корректировки ошибок необходимо существование интегрирующего соотношения между объясняемой и объясняющими переменными.

Вернёмся к выбору между различными видами транспорта. Как упоминалось выше, подход *SNCF* не очень удачен в силу того, что выбор происходит только между двумя видами транспорта, что нереалистично. Для решения этой проблемы следует при прогнозировании спроса на транспортные услуги учесть вариант модели для большего числа видов транспорта, который предлагается в работе, посвящённой

прогнозированию спроса на железнодорожный и другие виды транспорта в Гонконге и Шэньчжэнь [69].

Такая модель прогнозирования базируется на логистическом распределении (один из видов абсолютно непрерывных распределений, формой напоминает нормальное распределение, но имеет более «тяжёлые» хвосты и больший коэффициент эксцесса) и соответствует классу моделей оценки дискретного выбора [70], [71], а также учитывает более чем один вид транспорта:

$$P = \frac{1}{1 + e^{\alpha(GC_n - GC_r) - \beta}}, \quad (40)$$

где  $P$  - вероятность выбора вида транспорта;  $GC_r$  - обобщённые издержки для вида транспорта, на который переключаются пассажиры;  $GC_n$  - обобщённые издержки для остальных видов транспорта;  $\alpha, \beta$  - коэффициенты модели.

Трудности могут возникнуть с расчётом показателя обобщённых издержек для всех видов транспорта. Поскольку данный показатель усредняется по нескольким видам транспорта, сильное изменение в параметрах одного из видов транспорта окажет в такой модели влияние более слабое, чем в реальности. Для получения прогнозов спроса на транспортные услуги в денежном выражении, на основании полученных коэффициентов чувствительности и прогнозных значений значения факторов (ВРП, индекса тарифа и другие), подставив их в уравнения моделей, описанных выше, а также умножив на тарифы услуг для пассажиров, можно оценить прогнозы приростов спроса в денежном выражении на транспортные услуги на периоды времени, по которым есть прогнозные значения факторов.

#### **1.4 Анализ возможностей применения показателя энергопотребления в качестве фактора для прогнозирования изменений объемов пассажирских перевозок в регионе**

Для предоставления транспортных услуг населению транспортной системе требуется израсходовать некоторое количество не только времени, но и энергии (себестоимость оказания услуг). Обозначим этот теоретический минимум расхода энергии для  $j$ -ой транспортной услу-

ги  $g_j(t)$ . Фактический расход энергии на оказание  $j$ -той транспортной услуги обозначим  $b_j(t)$ . Отношение теоретического минимума затрат энергии к фактическому расходу на оказание  $j$ -ой транспортной услуги называют коэффициентом совершенства технологии, подробнее см. [72], [73], [74], [75]:

$$\eta_j(t) = \frac{g_j(t)}{b_j(t)}. \quad (41)$$

Установим связь между суммарным энергопотреблением в экономической системе и суммарным объемом оказания транспортных услуг, используя в качестве единицы времени например 1 час. Суммарное энергопотребление транспортной системы как целого может быть представлено как сумма оказания всех транспортных услуг.

Если  $j$ -ая услуга требует фактического расхода энергии  $b_j(t)$ , а количество единиц таких транспортных услуг, выходящего из  $j$ -го производственного процесса, составляет  $k_j(t)$  единиц, то потребляемая мощность на оказание этой услуги составит  $N_j(t)$ . При определении величины  $b_j(t)$  в киловатт-часах и определении объемов оказания транспортных услуги в час, мощность будет выражаться в киловаттах. В этом случае, объем оказания  $j$ -ой услуги может быть записан в виде:

$$k_j(t) \cdot b_j(t) = N_j(t), \quad (42)$$

где  $k_j(t)$  — количество  $j$ -ой услуги, оказываемой за 1 час;  $b_j(t)$  — фактические затраты энергии для оказания  $j$ -ой услуги;  $N_j(t)$  — фактическая величина мощности в киловаттах, потребляемая для оказания  $j$ -ой услуги.

Составляя объем оказания транспортных услуг в социально-экономической системе в целом (что возможно, так как все объемы оказания услуг приведены к одной и той же физической величине), мы получим часовой объем предоставления общественной услуги, или валовой продукт транспортной системы за 1 час:

$$P(t) = \sum_j k_j(t) \cdot g_j(t) = \sum_j N_j(t) \cdot \eta_j(t). \quad (43)$$

Таким образом, валовой продукт транспортной системы за 1 час

пропорционален не просто суммарному энергопотреблению, а произведению суммарного энергопотребления на обобщенный коэффициент полезного действия, или на коэффициент совершенства технологии на транспорте.

При одном и том же суммарном энергопотреблении возможно увеличивать объем оказываемых транспортных услуг в единицу времени за счет роста коэффициента совершенства технологии.

Если объем оказания  $j$ -ой услуги превосходит скорость ее потребления, то отношение скорости потребления к объему оказания услуги в единицу времени и даёт численное значение качества прогнозирования транспортного спроса. Таким образом, балансовое уравнение удовлетворения спроса на транспортные услуги можно представить в виде:

$$F(t) = \sum_j k_j(t) \cdot g_j(t) \cdot \varepsilon_j(t) = \sum_j N_j(t) \cdot C_j(t) \cdot \varepsilon_j(t), \quad (44)$$

где  $F(t)$  - удовлетворение потребностей в транспортных услугах за единицу времени,  $k_j(t)$  - объем  $j$ -ой услуги оказываемой в 1 час;  $g_j(t)$  - теоретически необходимые затраты мощности на единицу  $j$ -ой услуги;  $N_j(t)$  - фактическая величина мощности, потребляемая для оказания  $j$ -ой транспортной услуги;  $C_j(t)$  - коэффициент совершенства транспортных технологий;  $\varepsilon_j(t)$  - коэффициент качества прогнозирования спроса на транспортные услуги  $j$ -ой транспортной услуги.

Все фазы жизненного цикла можно разделить на три связанных между собой активных зон: зона развития или зона безопасности транспортной системы; переходная зона; зона деградации или зона опасности для транспортной системы.

Зона развития системы включает в себя следующие фазы циклов системы: устойчивое развитие системы при  $\ddot{P}(t^4) > 0$ ; развитие (неустойчивое) при  $\dot{P}(t^3) > 0$ ; ускоренный рост при  $\ddot{P}(t^2) > 0$ ; рост или становление при  $\dot{P}(t) > 0$ ; возникновение системы  $P > 0$ . Переходная зона – это нулевой рост или стагнация (застой) системы. Иногда эту зону называют зоной стабильности по аналогии с состоянием стабильности – равновесия в замкнутых системах. Как известно, в состоянии равновесия замкнутая система имеет максимальную энтропию и не способна совершать внешнюю работу. Такое понимание стабиль-

ности может вводить в заблуждение при анализе социальных систем, так как социальная система как и любая живая система (до тех пор, пока она жива) никогда не бывает в состоянии стабильности – равновесия и на протяжении всей своей жизни совершает работу против равновесия, то есть против роста энтропии – хаоса. Это положение в теории устойчивого развития носит название принципа устойчивой неравновесности.

В силу сказанного переходную зону можно назвать зоной мнимой или ложной стабильности. Выделяются два типа зоны мнимой стабильности (стагнации): переход от развития к деградации; переход от деградации к развитию с опасностью возврата к деградации. Зона опасностей системы включает в себя следующие фазы жизненного пути системы: затухание (спад) при  $\dot{P}(t) \leq 0$ ; ускоренный спад  $\ddot{P}(t^2) < 0$ ; деградация при  $\dot{P}(t^3) < 0$ ; распад при  $\ddot{P}(t^4) < 0$ ; исчезновение при  $P = 0$ .

Введённые актуальные зоны безопасности, стагнации, опасности дают возможность представить существование оцениваемой транспортной системы, как волнообразный процесс чередования фаз жизненного пути системы, что проиллюстрировано на рис. 4 [122]. При недостаточном уровне качества прогнозирования спроса на транспортные услуги в экономической системе могут возникать во времени как эффекты дефицита транспортных услуг (в том числе доступности и качества): на рис. 4 это интервал времени от  $t_4$  до  $t_6$ ; так и перепроизводства транспортных услуг, это интервалы времени от  $t_1$  до  $t_4$ . Получение оперативной информации о состоянии спроса на услуги пассажирского транспорта — актуальная задача современного общества, решение которой предоставит возможность не только удовлетворить потребность населения в передвижении при оптимальном использовании транспортных средств, но и повысить эффективность управления системой пассажирского транспорта.

Для повышения эффективности прогнозирования изменений объемов пассажирских перевозок и транспортного спроса представляется актуальным рассмотреть вопрос разработки и применимости методики прогнозирования транспортного спроса в зависимости от факторов внешней среды, которые изменяются в краткосрочном периоде (на Ри-






Рис. 4: Устойчивость транспортного спроса и предложения при краткосрочном и долгосрочном периоде прогноза

сунке 3 между интервалами времени от  $t_1$  до  $t_6$ ) с периодичностью изменения транспортного спроса за сутки, с использованием в качестве исходных данных выборки временных рядов: исследуемой переменной и факторов, от которой она зависит.

В качестве примера рассмотрим сопоставление изменений объемов пассажирских перевозок на отдельном виде городского пассажирского транспорта и потребления электрической энергии в регионе (транспортном районе). На рис. 5 представлено изменение среднесуточного объема перевозок московским метрополитеном за 14 лет по месяцам наблюдения и среднесуточное потребление электрической энергии в Москве и Московской области (по данным Системного оператора единой энергетической системы) [122], [76].

Как видно из графика, представленного на рис. 5, между временными рядами объем пассажирских перевозок Московским метрополитеном и потребление электрической энергии в Московской агломерации наблюдается определенная синхронность изменения и сопостави-




Рис. 5: Динамика изменений объемов пассажирских перевозок Московским метрополитеном и потребления электрической энергии в Московской агломерации за период с 2001 по 2014 год

мость динамики (косвенная взаимозависимость переменных): направленность трендов, синхронность динамики изменений годовой и сезонной составляющих, периодические изменения по месяцам наблюдений. По нашему мнению, динамика изменений потребления электрической энергии может стать одним из ключевых переменных для факторной математической модели, как показатель (индикатор) экономической активности.

Таким образом, развитие математических моделей, методов и алгоритмов прогнозирования изменений объемов пассажирских перевозок и транспортного спроса в зависимости от изменения внешних факторов, в том числе от потребления электрической энергии (как индикаторов социальной и экономической активности населения) на основе анализа и обработки временных рядов является новой прикладной задачей и рассмотрено в последующих главах.

## 1.5 Выводы к Главе 1

В Главе 1 формулируется постановка и концептуальная идея, решаемой в диссертационной работе задачи, отмечается ее важность и актуальность.

В главе были рассмотрены актуальные вопросы и проблемы использования современных подходов прогнозирования спроса на транспортные услуги. С помощью комплексного подхода, основанного на применении схем математической статистики и экономики, проведен анализ существующих подходов к прогнозированию спроса пассажиров на транспортные услуги (транспортный спрос). Получены условия применения схем прогнозирования и выявлены их особенности, сильные и слабые стороны, также рассмотрены используемые на практике факторы, влияющие на пассажирские перевозки.

В главе было показано, что в применяемых в настоящее время моделях и методика прогнозирования транспортного необходимо наличие прогнозных значений регрессоров (ВВП, численности населения, подвижности населения и др.).

Рассмотренные в Главе 1 методики оценки и прогнозирования транспортного спроса могут применяться для стратегического прогнозирования спроса на транспортные услуги (от одного года и более с временным шагом один год), что обусловлено периодичностью сбора и получения необходимой информации о действующих на спрос факторах: численность населения, ВРП, среднедушевой доход, транспортная подвижность населения и другие.

Показано, что валовой продукт транспортной системы пропорционален произведению суммарного энергопотребления на коэффициент совершенства технологии, используемого в транспортной отрасли, а при одном и том же суммарном потреблении можно увеличить объем транспортных услуг в единицу времени за счёт роста коэффициента совершенствования технологий. Автором обосновываются выводы, о том что изменение показателя энергопотребления в транспортном районе может выступать в качестве фактора изменений объемов пассажирских перевозок и транспортного, как характеристика транспортной подвижности населения и его активности в перемещениях. Показана актуальность и необходимость применения методов краткосроч-

ного прогнозирования транспортного спроса и его место в обеспечении устойчивой работы транспортной системы.

Оценки чувствительности потребностей пассажиров к различным факторам (социально-экономическим, финансовым, качественным характеристикам транспорта, инфраструктурным) являются частью прогнозирования спроса на транспортные услуги.

Значимость данной работы заключается в том, что точность прогноза изменений объемов пассажирских перевозок и транспортного спроса будет связана с точностью располагаемых исходных данными о показателях и факторах, от которых зависят пассажирские перевозки. Повышение точности прогнозирования можно осуществить используя для моделирования и прогнозирования спроса на услуги транспорта подход и методологию анализа временных рядов, при котором изменение факторов (период времени между наблюдениями) происходит в краткосрочном периоде. Теоретико-математические аспекты и необходимость применения методов краткосрочного прогнозирования были рассмотрены автором в разделе 1.4.

Получение оперативной информации о состоянии спроса на услуги пассажирского транспорта является актуальной задачей современного общества. Ее решение будет способствовать не только удовлетворению потребностей населения в передвижении при оптимальном использовании транспорта, но и повысит эффективность управления транспортной системой.

Разработка методов краткосрочного прогнозирования изменений объемов пассажирских перевозок и транспортного спроса связана с учетом многих факторов, которые образуются как под действием причинно-следственных связей, так и по причине неопределенности. Последние усложняют задачу и требуют использовать в комплексе функциональные и вероятностно – статистические методы для получения конкретных решений.

Методы прогнозирования, основанные на использовании в качестве исходных данных временных рядов, основаны на предположении, что факторы, влиявшие на активность в прошлом и влияющие в настоящем, будут действовать и в будущем, таким образом анализ временных рядов может представлять собой эффективное дополнительное

средство прогнозирования пассажирских перевозок. В качестве рассматриваемых факторов автором предполагается использование факторов, которые ранее не использовались для прогнозирования изменений объемов пассажирских перевозок и транспортного спроса, а также и оценить возможность их использования для математической модели.

Таким образом, автором в последующих главах рассматриваются вопросы развития математических моделей, методов и алгоритмов для прогнозирования изменений объемов пассажирских перевозок на основе временных рядов, которые смогут выступить в качестве альтернативного и эффективного инструмента прогнозирования краткосрочного изменения спроса на пассажирские перевозки в зависимости от факторов внешней среды и энергопотребления, как фактора, характеризующего социальную и экономическую активность населения в рассматриваемой системе.

## **2 Прогнозирование пассажирских перевозок в Московском метрополитене с помощью ИНС прямо-точного типа**

В 2015 году отмечалось 80 летие Московского метрополитена (ММ), который является основой транспортной системы столицы. Он надежно связывает центр города с промышленными районами и жилыми массивами. В 2012 году среднесуточный пассажиропоток составил 6,73 млн. пассажиров в сутки, а пиковый — 9,28 млн. пассажиров в сутки (29 ноября 2012). В настоящее время доля Московского метрополитена в перевозке пассажиров среди предприятий городского пассажирского транспорта столицы составляет около 56% [77].

С учетом динамики развития ММ и строительством в Москве современной транспортной инфраструктуры роль метрополитена в пассажирских перевозках будет только расти. Для обеспечения эффективного функционирования ММ необходимы постоянный мониторинг пассажирского трафика и прогнозирование объемов перевозок пассажиров на ближайшую и долгосрочную перспективу.

Получение оперативной информации о состоянии спроса на услуги пассажирского транспорта является актуальной задачей современного общества. Ее решение будет способствовать не только удовлетворению потребностей населения в передвижении при оптимальном использовании транспорта, но и повысит эффективность управления транспортной системой [78]. Ключевая роль в решении указанной проблемы отводится надежному прогнозированию объемов пассажирских перевозок на основе анализа соответствующих временных рядов [79, 80, 81].

В настоящей работе развита методика прогнозирования объемов пассажирских перевозок в ММ с помощью искусственных нейронных сетей. Такой подход к решению рассматриваемой задачи применяется впервые не только в России, но и в мире.

### **2.1 Анализ данных наблюдения и постановка задачи**

В данной главе рассматривается временной ряд, описывающий объемы перевозок пассажиров в ММ, анализируются факторы, которые влияют или могут влиять на пассажиропоток, и детально форму-

лируется решаемая задача.

## 2.2 Анализ временного ряда, описывающего объемы перевозок пассажиров

На рис. 6 приведен временной ряд, отражающий динамику суточного объема пассажирских перевозок Московским метрополитеном за последние 5 лет. На этом рисунке виден очень большой разброс в




Рис. 6: Динамика суточного объема пассажирских перевозок в Московском метрополитене за последние 5 лет

реализованных объемах перевозок. Главная причина такого разброса состоит в том, что пассажирские перевозки существенно различаются по своим объемам в рабочие и в выходные-праздничные дни.

На рис. 7 представлены распределения суточного объема пассажирских перевозок в рабочие (гистограмма справа) и в выходные-праздничные (гистограмма слева) дни.

Из приведенного рисунка видно, что указанные распределения сильно разнесены по своему среднему значению и, несмотря на то, что оба распределения имеют большие дисперсии, они практически (за исключением нескольких дней) не перекрываются.

На рисунках 8 и 9 представлены временные ряды, описывающие динамику суточного объема пассажирских перевозок, соответственно, в рабочие (рис. 8) и выходные-праздничные (рис. 9) дни.

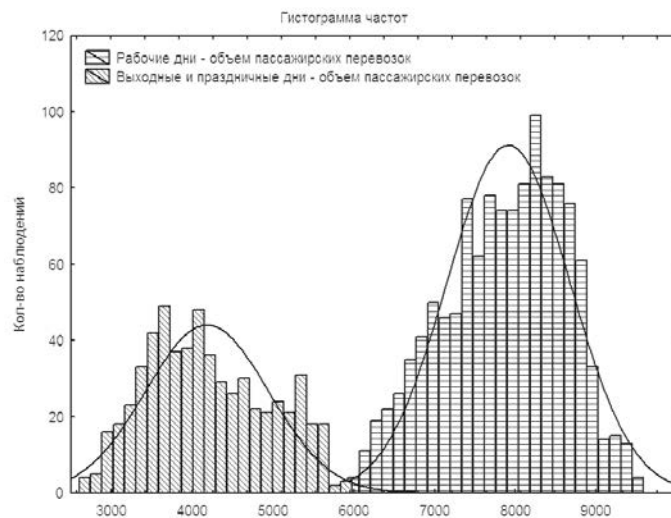


Рис. 7: Распределения суточного объема пассажирских перевозок в рабочие (справа) и выходные-праздничные (слева) дни, тыс. пасс.




Рис. 8: Динамика суточного объема пассажирских перевозок в рабочие дни

Из сравнения указанных временных рядов можно сделать вывод о том, что динамика суточного объема пассажирских перевозок в рабочие дни носит более регулярный характер и не столь сильно зашумлена, как это имеет место в выходные-праздничные дни.

В этой связи, имеет смысл исследовать по отдельности временные ряды, описывающие динамику суточного объема пассажирских перевозок в рабочие и выходные-праздничные дни.






Рис. 9: Динамика суточного объема пассажирских перевозок в выходные-праздничные дни

### 2.3 Анализ факторов, влияющих на суточные объемы пассажирских перевозок

В таблице 3 представлен перечень переменных величин, от которых зависит динамика суточных объемов перевозок пассажиров метрополитеном. По этим переменным была собрана база данных, включающая статистику ежедневных значений за последние 5 лет (всего 1823 дня наблюдений).

С целью оценки корреляционной связи между переменными  $Var6 \div Var15$  и суточными объемами пассажирских перевозок в рабочие дни (обозначаемых далее с помощью переменной  $Var16$ ) была сформирована матрица коэффициентов корреляций Пирсона [82] (см. таблицу 4).

Коэффициент корреляции Пирсона позволяет установить наличие линейной зависимости между двумя анализируемыми переменными величинами:

$$x^m = (x_1, \dots, x_m), \quad y^m = (y_1, \dots, y_m),$$

распределенных в соответствии с нормальным законом. Для этого вос-

№ п. п.	Наименование и обозначение временного ряда		Описательная статистика временного ряда						
			<i>Median</i>	<i>Minimum</i>	<i>Max</i>	<i>Percentile</i>	<i>Std.Dev.</i>	<i>Skewness</i>	<i>Kurtosis</i>
1	Год наблюдения	<i>Var1</i>	2012	2010	2014	2010	1,41	0,002911	-1,29974
2	Календарный месяц наблюдения	<i>Var2</i>	7	1	12	2,0	3,45	-0,01042	-1,20926
3	Календарная дата	<i>Var3</i>	16	1	31	4	8,81	0,005090	-1,19560
4	День недели Принимаемые значения: понедельник (1), вторник (2), среда (3), четверг (4), пятница (5), суббота (6), воскресенье (7).	<i>Var 4</i>	4,0	1,0	7,0	1,0	2,00	0,000000	-1,25309
5	Тип дня Принимаемые значения: послепраздничный (1), послевыходной (2), полный рабочий день (3), предвыходной (4), предпраздничный (5), выходной (6), праздничный (7).	<i>Var 5</i>	3	1	7	2	1,60	0,383699	-1,23308
6	Минимальная дневная температура воздуха (°C)	<i>Var 6</i>	3,2	-28,5	26,0	-12,7	10,58	-0,43024	-0,49971
7	Средняя дневная температура воздуха (°C)	<i>Var 7</i>	6,9	-23,8	30,8	-9,4	11,50	-0,22910	-0,76719
8	Максимальная дневная температура воздуха (°C)	<i>Var 8</i>	10,0	-19,7	38,2	-6,6	12,76	-0,06772	-0,96472
9	Отклонение дневной температуры воздуха от нормы (°C)	<i>Var 9</i>	1,1	-17,5	12,9	-5,4	4,80	-0,48484	0,25893
10	Суммарные дневные осадки (мм.)	<i>Var10</i>	0,0	0,0	38,9	0,0	4,07	3,686355	17,47308
11	Максимальная дневная загруженность автомобильных дорог в утренний час-пик (баллов)	<i>Var11</i>	42,5	6,5	86,0	15,0	17,92	0,019978	-0,86817
12	Максимальная дневная загруженность автомобильных дорог в вечерний час-пик (баллов)	<i>Var12</i>	45,1	10,5	96,0	18,7	18,17	0,102196	-0,87267
13	Суммарная дневная интернет-активность пользователей сети Интернет (дневная статистика запросов в поисковых системах)	<i>Var13</i>	5988,7	3302,4	23428	4299,1	3792,36	1,258097	0,83355
14	Общая суточная генерация электрической энергии в регионе (МВт*ч)	<i>Var14</i>	282536	188109	397609	230585,7	45073,86	0,186780	-1,04628
15	Общее суточное потребление электрической энергии в регионе (МВт*ч)	<i>Var15</i>	271337	198460,3	368755	226591,6	37583,01	0,222335	-1,04184

Таблица 3: Перечень переменных величин, влияющих на суточные объемы перевозок пассажиров Московским метрополитеном, с их основными статистическими характеристиками

пользуемся следующей формулой [82]:

$$r_{x,y} = \frac{\sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x})^2 \sum_{i=1}^m (y_i - \bar{y})^2}} = \frac{cov(x, y)}{\sqrt{s_x^2 s_y^2}}.$$

Здесь  $\bar{x}, \bar{y}$  - выборочные средние:

$$\bar{x} = \frac{1}{m} \sum_{i=1}^m x_i, \quad \bar{y} = \frac{1}{m} \sum_{i=1}^m y_i,$$

а  $s_x^2, s_y^2$  - выборочные дисперсии:

$$\sum_{i=1}^m (x_i - \bar{x})^2, \quad \sum_{i=1}^m (y_i - \bar{y})^2,$$

вычисленные для рассматриваемых наборов  $x^m$  и  $y^m$ .

Область изменения коэффициента Пирсона  $r_{xy} \in [-1, 1]$ . При этом, в случае  $|r_{xy}|=1$ , переменные  $x, y$  линейно зависимы, если же  $r_{xy} = 0$ , то  $x, y$  линейно независимы.

	Var6	Var7	Var8	Var9	Var10	Var11	Var12	Var13	Var14	Var15	Var16
Var6	1,00	<b>0,98</b>	<b>0,95</b>	<b>0,63</b>	<b>0,08</b>	<b>-0,37</b>	<b>-0,37</b>	<b>-0,13</b>	<b>-0,87</b>	<b>-0,90</b>	<b>-0,52</b>
Var7	<b>0,98</b>	1,00	<b>0,99</b>	<b>0,62</b>	0,03	<b>-0,43</b>	<b>-0,43</b>	<b>-0,09</b>	<b>-0,90</b>	<b>-0,92</b>	<b>-0,55</b>
Var8	<b>0,95</b>	<b>0,99</b>	1,00	<b>0,58</b>	-0,00	<b>-0,46</b>	<b>-0,46</b>	<b>-0,06</b>	<b>-0,91</b>	<b>-0,93</b>	<b>-0,56</b>
Var9	<b>0,63</b>	<b>0,62</b>	<b>0,58</b>	1,00	-0,00	-0,01	-0,02	<b>-0,19</b>	<b>-0,37</b>	<b>-0,39</b>	<b>-0,12</b>
Var10	<b>0,08</b>	0,03	-0,00	-0,00	1,00	<b>0,36</b>	<b>0,34</b>	<b>-0,35</b>	-0,03	-0,01	-0,00
Var11	<b>-0,37</b>	<b>-0,43</b>	<b>-0,46</b>	-0,01	<b>0,36</b>	1,00	<b>0,97</b>	<b>-0,75</b>	<b>0,42</b>	<b>0,49</b>	<b>0,61</b>
Var12	<b>-0,37</b>	<b>-0,43</b>	<b>-0,46</b>	-0,02	<b>0,34</b>	<b>0,97</b>	1,00	<b>-0,79</b>	<b>0,41</b>	<b>0,49</b>	<b>0,60</b>
Var13	<b>-0,13</b>	<b>-0,09</b>	<b>-0,06</b>	<b>-0,19</b>	<b>-0,35</b>	<b>-0,75</b>	<b>-0,79</b>	1,00	<b>0,16</b>	<b>0,09</b>	<b>-0,34</b>
Var14	<b>-0,87</b>	<b>-0,90</b>	<b>-0,91</b>	<b>-0,37</b>	-0,03	<b>0,42</b>	<b>0,41</b>	<b>0,16</b>	1,00	<b>0,97</b>	<b>0,52</b>
Var15	<b>-0,90</b>	<b>-0,92</b>	<b>-0,93</b>	<b>-0,39</b>	-0,01	<b>0,49</b>	<b>0,49</b>	<b>0,09</b>	<b>0,97</b>	1,00	<b>0,59</b>
Var16	<b>-0,52</b>	<b>-0,55</b>	<b>-0,56</b>	<b>-0,12</b>	-0,00	<b>0,61</b>	<b>0,60</b>	<b>-0,34</b>	<b>0,52</b>	<b>0,59</b>	1,00

Таблица 4: Матрица коэффициентов корреляций Пирсона для всех сочетаний переменных Var6÷Var16

В таблице 4 серым цветом отмечены те ячейки таблицы, для которых имеет место явление мультиколлениарности [84, 85] – сильная корреляционная связь ( $> 0,8$ ) между разными переменными.

В результате анализа матрицы корреляций для дальнейшего рассмотрения были оставлены только такие переменные:

- для которых не наблюдается явление мультиколлениарности;
- которые имеют значимый характер для ИНС, обусловленный сезонностью прогнозируемой величины;
- для которых на практике можно получить достоверные прогнозные значения с использованием альтернативных методов получения информации.

Переменные Var6, Var7, Var8, Var14 были исключены нами из дальнейшего рассмотрения из-за того, что они мультиколлениарны с переменной Var15. При этом переменная Var15 обладает сопоставимой (в сравнении с исключаемыми переменными) корреляцией с переменной Var16 и, что более важно, для Var15 нами исследована и показана возможность получать приемлемые прогнозные значения с помощью ИНС. Переменная Var10 была исключена из-за отсутствия корреляции с прогнозируемой величиной. Переменные Var11÷Var13 были исключены из дальнейшего анализа исходя из практических соображений: нет возможности получения в качестве исходных данных приемлемых прогнозных значений с использованием альтернативных методов получения информации.

## 2.4 Постановка задачи

Таким образом, с учетом вышесказанного, из всего набора данных, приведенного в таблице 3, для последующего использования нами были отобраны следующие переменные: Var1, Var2, Var4, Var5, Var9 и Var15. Эти переменные вместе со значением прогнозируемой переменной Var16 на текущий день образуют выборку данных, которые будут подаваться на вход предварительно обученной нейронной сети (о чем пойдет речь в следующем разделе главы), а на выходе сети мы

должны получать прогнозируемые на следующие дни объемы пассажирских перевозок.

## 2.5 Прогнозирование пассажирских перевозок с помощью ИНС прямоточного типа

Искусственные нейронные сети широко и успешно применяются во многих задачах науки, техники, экономики и бизнеса, связанных с анализом и обработкой данных наблюдения, в том числе таких как: анализ изображений, прогнозирование поведения финансовых рядов, распознавание образов (в частности, отделение сигнала от фона в задачах физики высоких энергий) и др. [86, 87].

Наиболее подходящей архитектурой ИНС для нашей задачи является многослойный перцептрон (МСП) (смотри, например, [87, 88]). МСП содержит несколько слоев нейронов: слой входных нейронов, один или несколько скрытых слоев и слой выходных нейронов. Связи в такой сети организованы между соседними слоями, а передача информации происходит в одном направлении: от входного слоя к выходному.

### 2.5.1 Архитектура и основные принципы работы многослойного перцептрона (МСП)

На рис. 10 приведена схема многослойного перцептрона с двумя скрытыми слоями и одним выходным нейроном: стрелками указаны направления передачи информации в сети.

Здесь  $x_k$  обозначают нейроны входного слоя,  $h_j$  и  $h_i$  – нейроны двух скрытых слоев, а  $y_0$  – выходной нейрон;  $w_{jk}$  – весовые связи (веса) входных нейронов с первым скрытым слоем,  $w_{ij}$  – веса связи нейронов первого скрытого слоя с нейронами второго скрытого слоя,  $w_{0i}$  – веса связи нейронов второго скрытого слоя с выходным нейроном. Сигналы  $a_j = \sum_k w_{jk}x_k$  и  $a_i = \sum_j w_{ij}h_j$  поступают на входы нейронов первого и второго скрытых слоев, а сигнал  $a_0 = \sum_i w_{0i}h_i$  подается на выходной нейрон.

Величины сигналов с выходов нейронов указанных слоев опреде-

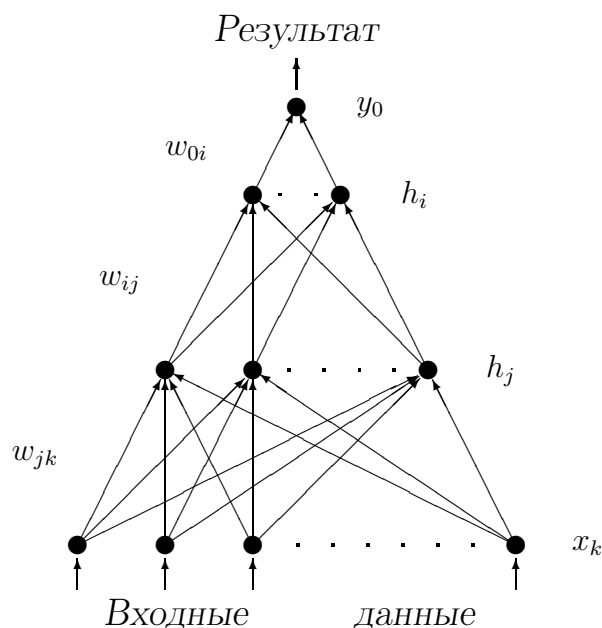


Рис. 10: Схема многослойного перцептрона с двумя скрытыми слоями и одним выходным нейроном

ляются из соотношений:

$$h_j = g(a_j/T) + \theta_j, \quad h_i = g(a_i/T) + \theta_i, \quad y_0 = g(a_0/T) + \theta_0,$$

где  $g(a, T)$  – переходная функция ( $T$  – “температура”, которая определяет величину ее наклона), а  $\theta$  – величина порога соответствующего нейрона. Чаще всего в МСП используется переходная функция сигмоидного вида  $g(x) = \frac{1}{2}[1 + \tanh(x)]$ .

Настройка сети (определение весовых и пороговых коэффициентов) на решаемую задачу проводится путем ее обучения, что обычно реализуется с помощью алгоритма обратного распространения ошибок [89].

В процессе обучения нейронной сети происходит ее настройка на анализируемые образцы, что реализуется путем коррекции набора весов:  $w_{jk}$ ,  $w_{ij}$  и  $w_{0i}$ . Эта процедура решается минимизацией функционала ошибок (называемого также функционалом энергии сети). Функционал ошибок  $E$  представляет собой сумму разностей между выход-

ными сигналами и эталонными значениями:

$$E = \frac{1}{2} \sum_p (y_0^{(p)} - t_0^{(p)})^2, \quad (45)$$

где  $p$  – номер входного образца из того набора данных, которые будут использоваться для обучения сети,  $y_0^{(p)}$  – значение с выходного нейрона в  $p$ -ом событии, а  $t_0^{(p)}$  – величина соответствующего эталона.

Выходные сигналы со скрытых и выходного слоев являются функциями от соответствующих весов. Изменения весов  $w_{jk}$ ,  $w_{ij}$  и  $w_{0i}$ <sup>1</sup> на каждой итерации можно записать в виде:

$$\Delta\omega_{0i} = -\eta \frac{\partial E}{\partial \omega_{0i}}, \quad \Delta\omega_{ij} = -\eta \frac{\partial E}{\partial \omega_{ij}}, \quad \Delta\omega_{jk} = -\eta \frac{\partial E}{\partial \omega_{jk}}. \quad (46)$$

Если подробно расписать отдельные выражения в (46), то получим:

$$\frac{\partial E}{\partial \omega_{0i}} = \frac{\partial E}{\partial y_0} \frac{\partial y_0}{\partial a_0} \frac{\partial a_0}{\partial \omega_{0i}} = \delta_0 g'(a_0) h_i, \quad (47)$$

$$\frac{\partial E}{\partial \omega_{ij}} = \delta_0 g'(a_0) \sum_i \omega_{0i} g'(a_i) h_j, \quad (48)$$

и

$$\frac{\partial E}{\partial \omega_{jk}} = \delta_0 g'(a_0) \sum_i \omega_{0i} g'(a_i) \omega_{ij} g'(a_j) x_k, \quad (49)$$

где переменная  $\delta_0$  определяется из следующего выражения:

$$\delta_0 = y_0 - t_0,$$

а  $t_0$  – эталонное значение для выходного нейрона.

Таким образом, для корректировки связей между скрытым и выходным слоями мы имеем:

$$\Delta\omega_{0i} = -\eta \delta_0 g'(a_0) h_i + \alpha \Delta\omega_{0i}^{old}. \quad (50)$$

Аналогично, для связей между скрытыми и входным слоями, получаем следующие выражения:

$$\Delta\omega_{ij} = -\eta \delta_0 g'(a_0) \sum_i \omega_{0i} g'(a_i) h_j + \alpha \Delta\omega_{ij}^{old} \quad (51)$$

---

<sup>1</sup>Для проведения указанных вычислений обычно используется метод градиентного спуска.

и

$$\Delta\omega_{jk} = -\eta\delta_0g'(a_0) \sum_i \omega_{0i}g'(a_i)\omega_{ij}g'(a_j)x_k + \alpha\Delta\omega_{jk}^{old}, \quad (52)$$

В выражениях (50), (51) и (52) параметр  $\eta$  позволяет контролировать скорость обучения нейронной сети [89], а параметры  $\alpha\Delta\omega_{0i}^{old}$ ,  $\alpha\Delta\omega_{ij}^{old}$  и  $\alpha\Delta\omega_{jk}^{old}$  представляют собой моменты, которые гасят осцилляции на выходе нейронной сети. Процедура обучения сети продолжается до тех пор, пока выходные сигналы не приблизятся к эталонным значениям.

Следует отметить, что на практике веса обычно корректируются не для каждого отдельного события, а на небольшой выборке событий. Это позволяет ускорить тренировочный процесс. Обычно достаточно сделать несколько десятков итераций на всей тренировочной выборке для того, чтобы минимизировать функционал ошибок и получить искомый набор весов. После завершения тренировочного процесса веса фиксируются, а качество обучения сети оценивается путем прогонки через нее тестовой выборки событий.

### 2.5.2 Структура сети и первые результаты прогнозирования

На этапе построения структуры МСП необходимо: 1) выбрать число слоев, 2) задать количество нейронов в каждом слое, 3) определить формат входных данных.

Анализируемые данные подаются на входные нейроны; число этих нейронов определяется объемом анализируемой выборки. Как отмечалось выше (смотри раздел 2.4), на вход сети будет подаваться выборка, включающая 7 переменных: Var1, Var2, Var4, Var5, Var9, Var15 и Var16. В теории, одного скрытого слоя в МСП достаточно для аппроксимации любой непрерывной функции [90]. Однако на практике для аппроксимации таких сложных временных рядов, как в нашем случае, лучший результат дает МСП с двумя скрытыми слоями: смотри, например, [91] и ссылки в ней. Число нейронов в скрытых слоях подбиралось нами исходя из результатов обучения сети на анализируемых данных. Результаты анализа входных выборок определяются по величине сигнала с выходного нейрона.

Перед тем, как приступить к работе с МСП, переменные Var1,



Var2, Var4, Var5, Var9, Var15 и Var16 (обозначим их через переменную  $z$ ) были приведены к диапазону  $[-1;+1]$  с помощью следующего преобразования:

$$x_i = \frac{(z_i - A_i) \cdot 2}{B_i - A_i} - 1, \quad i = 0, 1, \dots, k, \quad (53)$$

где  $z_i$  – исходное значение переменной  $z$ ,  $A_i$  и  $B_i$  – минимальное и максимальное значения переменной  $z_i$ , а  $x_i$  – значение нормированной переменной.

В настоящей работе использовался многослойный перцептрон из пакета TMVA 4.2.0 [92] в среде ROOT [93].

Структура сети была следующей: 7 нейронов на входе, первый скрытый слой содержал 16 нейронов, второй - 8 нейронов, один выходной нейрон. Для обучения сети использовалась выборка, содержащая 1200 наблюдений. В результате проведенного нами анализа для обучения был выбран метод Флетчера - Ривса (*Fletcher-Reeves*) (смотри, например, [94], [95], [96]), обеспечивший наилучшие результаты на этапе обучения и при тестировании МСП.

На рис. 11 приведен график изменения ошибки при обучении ИНС в зависимости от номера эпохи. Процедура обучения включала 1500 эпох.




Рис. 11: График изменения ошибки при обучении ИНС в зависимости от номера эпохи

После завершения процедуры обучения МСП и фиксации весов оценивалось качество прогноза. Прогноз строился по последним 28 на-

блюдениям. На рис. 12 приведено распределение относительной ошибки  $R_y$

$$R_y = \frac{y_{real} - y_{prog}}{y_{real}}, \quad (54)$$

где  $y_{real}$  – наблюдаемое (реальное) значение объема пассажироперевозок, а  $y_{prog}$  – прогноз, полученный с помощью МСП.




Рис. 12: Распределение относительной ошибки при тестировании обученной сети

Полученные результаты продемонстрировали принципиальную возможность применения данного подхода для прогнозирования объемов пассажирских перевозок на метрополитене.

## 2.6 Вейвлет-фильтрация суточных объемов пассажирских перевозок

В разделах 2.1.-2.5. была развита методика прогнозирования объемов пассажирских перевозок в Московском метрополитене с помощью искусственных нейронных сетей. Полученные результаты продемонстрировали принципиальную возможность применения такого подхода. Однако достигнутой при этом точности вряд ли можно было считать удовлетворительной. Для того, чтобы повысить точность и увеличить горизонт прогноза можно предварительно, до обучения ИНС, провести фильтрацию анализируемого временного ряда с целью исключения из него шумовой компоненты.

Временной ряд, отвечающий объемам пассажирских перевозок в ММ, может быть представлен в виде:

$$f(t_i) = x_i = x[(i - 1)\Delta t], \quad i = 1, 2, \dots, K, \quad (55)$$

где  $\Delta t$  - интервал выборки ( $\Delta t = 1$  в нашем случае).

Мы можем представить рассматриваемый временной ряд в виде регулярного процесса и стохастической составляющей, играющей роль высокочастотного шума. Исключение из измерений указанного шума должно повысить точность и увеличить горизонт прогноза.

Вейвлет-анализ является эффективным инструментом для анализа таких динамических процессов, как исследуемый нами временной ряд, позволяя сосредоточиться на ограниченных фрагментах ряда наряду с процедурой изменения масштаба, обеспечивающей возможность изучения отдельных его фрагментов на разных масштабах.

### 2.6.1 Общая схема вейвлет-фильтрации

Кратко изложим общую схему вейвлет-анализа. Детали можно найти, например, в работах [97, 98].

Дискретное вейвлет-преобразование (ДВП) функции  $f(t) \in L_2(R)$ , заданной в виде одномерного временного ряда (55), может быть представлено в виде следующего разложения

$$f(t) = \sum_{j,k \in Z} d_{jk} \psi(2^j t - k). \quad (56)$$

Здесь набор базисных функций (вейвлетов)  $\{\psi_{jk}(t) = \psi(2^j t - k), j, k \in Z\}$  получается из “родительской” вейвлет-функции  $\psi(t) \in L_2(R)$ , применением двоичного разложения  $2^j$  и бинарной трансляции  $k/2^j$ .

Согласно мультиразложения вейвлет-анализа равенство (56) может быть переписано в более удобной форме:

$$f(t) = \sum_k s_k^J \phi(2^J t - k) + \sum_{j \geq J} \sum_{k \in Z} d_k^j \psi(2^j t - k), \quad (57)$$

где  $\phi(t)$  - функция масштабирования, соответствующая выбранной вейвлет-функции  $\psi(t)$  (смотри, например, [97]). В (57) первый член описывает гладкую (низкочастотную) составляющую ряда (57), ограниченную уровнем точности  $J$ , а второй член связан с высокочастотной составляющей анализируемого ряда.

Коэффициенты  $s_k^j$  и  $d_k^j$  обычно определяются с помощью пирамидальной схемы [98] быстрых вейвлет-преобразований (смотри, например, [99]), используя следующие соотношения:

$$s_k^{j+1} = \sum_m h_m s_{2k+m}^j, \quad d_k^{j+1} = \sum_m g_m s_{2k+m}^j, \quad (58)$$

где  $h_m$  и  $g_m$  – коэффициенты низко- и высоко-частотных фильтров, соответственно.

Нами использовались дискретные вейвлеты Добечи [97, 100], так как данные вейвлеты обеспечивают наилучшее описание как высоко-частотных, так низкочастотных составляющих анализируемого ряда [99].

Вейвлет-фильтрация подразумевает отбрасывание или модификацию части коэффициентов разложения с абсолютными значениями меньшими некоторого наперед заданного порогового значения  $\lambda$ . Существуют различные алгоритмы вейвлет-фильтрации, среди которых наиболее распространенным является жесткий пороговый алгоритм (смотри, например, [99]). В этом алгоритме все коэффициенты с абсолютными значениями меньшими  $\lambda$  отбрасываются, а точнее, приравниваются нулю.

В таких алгоритмах процедура фильтрации воздействует на все коэффициенты, без учета соответствующего им разрешающего уровня  $J$ . Поэтому такая процедура может приводить к отбрасыванию не только коэффициентов  $\{d_k^j\}$ , соответствующих высокочастотной составляющей (57), но и коэффициентов  $\{s_k^J\}$ , которые отвечают за низкочастотную компоненту временного ряда.

Для того, чтобы исправить указанный недостаток, в работе [101] была предложена модификация алгоритма с жесткой пороговой схемой таким образом, чтобы фильтрация коэффициентов вейвлет-разложения проводилась с учетом разрешающего уровня  $J$ .

Процедура фильтрации в модифицированном алгоритме выполняется следующим образом. Пусть  $K$  – это количество элементов в анализируемом ряду, а  $M$  – число коэффициентов, которые должны быть отброшены, и предположим, что  $M < \frac{K}{2}$ . В этом случае отбрасываются  $M$  наименьших коэффициентов из числа  $\frac{K}{2}$  коэффициентов, отвечающих высокочастотной составляющей анализируемого ряда (57). Если

$\frac{K}{2} < M < \frac{3K}{4}$ , то отбрасываются все  $\frac{K}{2}$  высокочастотных коэффициентов, а также  $M - \frac{K}{2}$  наименьших коэффициентов, ответствующих более низкому уровню аппроксимации  $J$  (полное число таких коэффициентов составляет  $\frac{K}{4}$ ).

По сравнению с традиционным алгоритмом фильтрации модифицированная схема обеспечивает более эффективное удаление высокочастотной компоненты из исходных измерений анализируемого ряда.

После применения ДВП,  $M$  отобранных коэффициентов приравниваются нулю. Затем, используя обратное вейвлет-преобразование, восстанавливается регулярная составляющая временного ряда. Разница между исходным временным рядом и отфильтрованным сигналом рассматривается нами как шум.

### 2.6.2 Вейвлет-фильтрация измерений пассажиропотока

На рис. 13 представлены (сверху-вниз): 1) исходный временной ряд, содержащий измерения пассажиропотока (последние 1024 рабочих дня из полного ряда в 1229 рабочих дня); 2) указанный ряд после применения к нему вейвлет-фильтрации (оставлено 256 коэффициентов из 1024); 3) исключенная из исходного ряда шумовая компонента.

На рис. 14 приведено распределение шумовой компоненты исследуемого нами временного ряда. На этом же рисунке представлен результат проверки нулевой гипотезы о соответствии наблюдаемой случайной величины нормальному распределению с помощью критерия согласия  $\chi^2$  (известного также, как критерий согласия Пирсона) [102]. Процедура фитирования была реализована с помощью пакета MINUIT [103] в среде широкоизвестного графического пакета PAW (Physical Analysis Workstation) [104].

В представленном на рис. 14 примере при числе степеней свободы  $\text{ndf}=48$  уровню значимости  $\alpha=5\%$  отвечает критическая граница, равная 65,2. Это означает, что только в 5% случаев величина критерия  $\chi^2$  может превысить указанную границу. Полученное в нашем случае  $\chi^2 = 50,97$  (см. рис. 14) значительно меньше указанного критического значения, что дает нам основание считать, что рассматриваемая случайная величина распределена по нормальному закону.

Для дополнительной проверки нашего предположения о том, что




Рис. 13: Сверху-вниз: 1) исходный временной ряд, содержащий данные о пассажиропотоке за последние 1024 рабочих дня (из полного ряда в 1229 рабочих дня); 2) указанный ряд после применения к нему вейвлет-фильтрации (оставлено 256 коэффициентов из 1024)); 3) исключенная из исходного ряда шумовая компонента

выделенную с помощью вейвлет-фильтрации компоненту можно считать шумом, использовался критерий симметрии на основе статистики  $\omega_n^2$  [105]. Данный критерий проверяет симметричность относительно  $x = 0$  функции распределения  $F(x)$  измерений  $X_1, \dots, X_n$ , т.е. нулевую гипотезу  $H_0: F(x) = 1 - F(x)$ .

Соответствующая статистика  $\omega_n^2$  имеет следующий вид:

$$\omega_n^2 = n \int_{-\infty}^{\infty} [F_n(x) + F_n(-x) - 1]^2 dF_n(x), \quad (59)$$

где  $F_n(x)$  - эмпирическая функция распределения. Для расчета вели-




Рис. 14: Распределение шумовой компоненты (нижний ряд на рис. 13): разность между исходным (верхний ряд на рис. 13) и отфильтрованным (средний ряд на рис. 13) временными рядами

чины статистики (59) удобнее использовать сведущую формулу:

$$\omega_n^2 = \sum_{j=1}^n \left[ F_n(-X_{(j)}) - \frac{n-j+1}{n} \right]^2,$$

где  $X_{(1)} \leq \dots \leq X_{(n)}$  - вариационный ряд, построенный на основе данных анализируемого ряда.

Исследуемый нами временной ряд содержит выборку объемом  $n = 1024$ , поэтому можно воспользоваться таблицами предельных функций для статистик  $\omega^2$  (см. [105]). Для критерия симметрии  $\omega^2$  критическая граница, отвечающая уровню значимости  $\alpha=5\%$ , составляет примерно 1,66. Значение же статистики  $\omega_n^2$ , вычисленное для шумовой компоненты, равняется 0,5687, что значительно меньше указанного критического значения. Таким образом, исследуемый ряд с высоким

уровнем надежности удовлетворяет рассмотренной нулевой гипотезе.

Прогнозирование временного ряда возможно только тогда, когда существует связь последующих значений ряда от предыдущих. Горизонт прогноза анализируемого нами ряда можно оценить с помощью линейной автокорреляционной функции [106]:

$$C(\tau) = \frac{\sum_{i=1}^N (x_{i+\tau} - \bar{x})(x_i - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2}, \quad (60)$$

где  $N$  - это число измерений в анализируемом временном ряде  $\{x_i\}$ , а

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i.$$

В качестве оценки интервала корреляции  $\tau$  – горизонта прогноза принимается величина первого пересечения автокорреляционной функцией временной оси в доверительном интервале, отвечающем белому шуму [107, 108].

На рис. 15 приведены зависимости автокорреляционной функции от величины интервала корреляции  $\tau$  для шумовой (слева) и регулярной (справа) составляющих временного ряда.

На рис. 15 (слева) видно, что для шумовой компоненты  $C(\tau)$  при  $\tau = 1$  обращается в ноль. Из этого следует, что соседние члены рассматриваемого временного ряда некоррелированы. Абсолютные значения  $C(\tau)$  для  $\tau > 1$  малы и с ростом  $\tau$  быстро спадают по абсолютной величине. Учитывая то, что реализации рассматриваемого ряда распределены согласно гауссовского закона и симметричны относительно нуля, можно сделать вывод о том, что данный ряд представляет собой гауссовский шум.

Исходя из поведения зависимости автокорреляционной функции от величины интервала корреляции  $\tau$  для регулярной компоненты (см. рис. 15(справа)) временного ряда, можно сделать вывод о том, что указанный ряд предоставляет возможности для среднесрочного прогноза.






Рис. 15: Поведение автокорреляционной функции  $C(\tau)$  в зависимости от интервала корреляции  $\tau$  для шумовой (слева) и регулярной (справа) составляющих временного ряда

## 2.7 Анализ полученных результатов

При количественной оценке функционирования МСП для регулярной составляющей временного ряда объемов пассажироперевозок структура сети, процедура тестирования не менялись.

На рис. 16 приведен график изменения ошибки при обучении МСП в зависимости от номера эпохи для отфильтрованных данных.




Рис. 16: График изменения ошибки при обучении МСП в зависимости от номера эпохи для отфильтрованных данных

На рис. 17 приведено распределение относительной ошибки  $R_y$

(см. равенство (69)) при тестировании обученной сети. Из этого рисунка следует, что в результате фильтрации исходных данных средне-квадратичное отклонение указанного распределения, по сравнению со средне-квадратичное отклонением для распределения, приведенного на рис. 12, уменьшилось практически в 4 раза.




Рис. 17: Распределение относительной ошибки при тестировании обученной сети

Для того, чтобы количественно оценить возможности прогнозирования с помощью ИНС, обученной на отфильтрованных данных, нами была построена зависимость средне-квадратичного отклонения для распределения относительной ошибки (получаемой при тестировании обученной сети) от горизонта прогнозирования (рис. 18). Здесь RMS (Root Mean Square) – это обозначение средне-квадратичного отклонения, используемое в пакетах PAW и ROOT [104, 93].

Из приведенной на рис. 18 зависимости видно, что в результате применения вейвлет-фильтрации к исходным данным удается существенно повысить точность прогноза и, как следствие, увеличить горизонт прогнозирования.

На рис. 19 представлены фактические объемы пассажирских перевозок метрополитеном на период 60 и 90 дней и значения, предсказанные с помощью искусственной нейронной сети. Как видно из рис. 19 прогнозные ИНС значения объемов пассажирских перевозок отличаются от фактических на величину порядка 4% при горизонте прогноза в 60 дней и порядка 14% при горизонте прогноза в 90 дней.

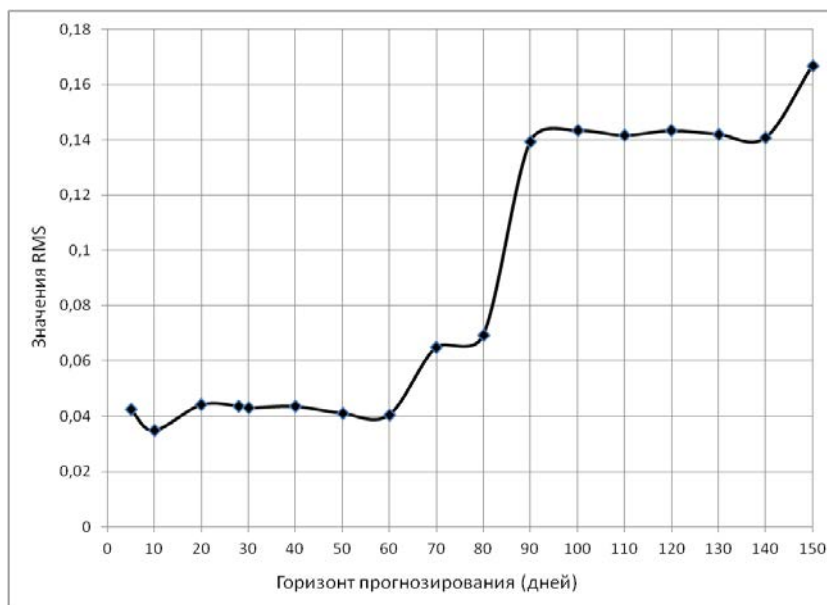


Рис. 18: Зависимость средне-квадратичного отклонения для распределения относительной ошибки при тестировании обученной сети от горизонта прогнозирования




Рис. 19: Фактические и прогнозные значения объемов пассажирских перевозок метрополитеном

## 2.8 Выводы к Главе 2

В настоящей главе развит новый подход для прогнозирования объемов пассажирских перевозок в Московском метрополитене с помощью искусственных нейронных сетей.

Анализ исследуемых временных рядов показал, что объемы пассажирских перевозок существенно различаются по своим объемам в рабочие и в выходные-праздничные дни. Кроме того, суточный объем перевозок пассажиров в рабочие дни носит более регулярный характер и не столь сильно зашумлен. Поэтому для оценки возможностей прогноза с помощью ИНС в этой работе нами использовались данные суточного объема пассажирских перевозок в рабочие дни.

Большие усилия были потрачены на этапе отбора тех факторов, которые могут влиять на суточные объемы перевозок пассажиров в ММ. В результате проведенного анализа из полного набора 15 факторов были отобраны только такие факторы, которые играют ключевую роль в обучении ИНС. Однако, из-за того, что исходный ряд был зашумлен, сразу не удалось получить приемлемой точности и горизонта прогноза. Для исключения шума из анализируемого ряда была применена вейвлет-фильтрация исходных данных. Эта процедура позволила более чем в четыре раза повысить горизонт прогноза.

ИНС с одним скрытым слоем плохо обучалась и, как следствие, с ее помощью нельзя было делать приемлемого прогноза. Поэтому использовался многослойный перцептрон с двумя скрытыми слоями, применение которого к анализируемым данным показало, что прогнозирование на основе ИНС указанного типа возможно.

### **3 Прогнозирование суточного потребления электроэнергии в Московской агломерации**

В Главе 2 для обучения и прогнозирования с помощью ИНС прямого типа на вход нейронной сети подавалась выборка, составленная из ключевых факторов, от которых зависит суточный объем перевозок пассажиров в Московском метрополитене. Один из таких факторов – это суточное потребление электроэнергии в Московской агломерации; при этом нами была установлена достаточно сильная корреляция указанного фактора и суточного объема перевозок пассажиров в Московском метрополитене.

В связи с вышеизложенным, для прогнозирования суточных объемов пассажирских перевозок в метрополитене с помощью ИНС, нужно предварительно спрогнозировать суточное энергопотребление в Московской агломерации (Москва и Московская область). Решению указанной задачи посвящена настоящая глава.

#### **3.1 Динамика энергопотребления в Московской агломерации**

На рис. 20 представлен временной ряд, отражающий динамику суточного энергопотребления в Московской агломерации за последние 14 лет (всего 5114 наблюдений).

Принимая во внимание тот факт, что в главах 2-3 прогнозирование суточных объемов пассажирских перевозок в метрополитене проводилось только в будние дни, из временного ряда, приведенного на рис. 20, нами были исключены выходные дни.

На рис. 21 представлен временной ряд, из которого удалены только выходные дни (всего 3654 наблюдений). Для того, чтобы исключить из указанных данных праздничные дни за последние 14 лет, нужно проделать довольно большую рутинную работу. По нашему мнению, праздничные дни, не удаленные из исходных данных, не должны хоть как-то заметно повлиять на окончательный результат. Поэтому данная процедура не проводилась.

Заметим, что после исключения из исходных данных выходных дней, рассматриваемый временной ряд стал выглядеть менее зашум-




Рис. 20: Динамика суточного энергопотребления в Московской агломерации за последние 14 лет




Рис. 21: Динамика суточного энергопотребления в Московской агломерации в будние дни

ленным (см. рис. 21).

Далее, временной ряд, представленный на рис. 21, также, как и в нашей предыдущей работе [124], был подвергнут процедуре вейвлет-фильтрации. Мы исходили из того, что исследуемый временной ряд может быть представлен в виде суммы регулярного процесса и стохастической составляющей, играющей роль высокочастотного шума. Исключение из этих измерений указанного шума позволяет повысить точность и увеличить перспективу прогноза [124].

Нами анализировались результаты вейвлет-фильтрации исходного временного ряда, содержащего данные суточного потребления электроэнергии за первые 2048 рабочих дня (из полного ряда в 3654 рабочих дней), при отбрасывании шумовой компоненты, включающей разное количество коэффициентов разложения.

Также, как и в Главе 2, для определения возможного количества отбрасываемых вейвлет-коэффициентов и оценки горизонта прогноза, анализировалось поведение линейной автокорреляционной функции [106].

В качестве оценки интервала корреляции  $\tau$  – горизонта прогноза принималась величина первого пересечения функцией  $C(\tau)$  оси абсцисс в доверительном интервале, отвечающему белому шуму [107, 108].

На рис. 22 (слева) приведена зависимость автокорреляционной функции от величины интервала корреляции  $\tau$  для шумовой компоненты временного ряда: число отбрасываемых коэффициентов равняется 1518 (чтобы минимизировать возможную примесь шума в регулярной компоненте, количество отбрасываемых коэффициентов было взято максимально возможным).




Рис. 22: Поведение автокорреляционной функции  $C(\tau)$  в зависимости от интервала корреляции  $\tau$  для шумовой компоненты (слева) и для регулярной составляющей временного ряда (справа)

Видно, что для шумовой компоненты  $C(\tau)$  при  $\tau = 1$  пересекает

ось абсцисс. Это означает, что соседние члены рассматриваемого ряда некоррелированы. Абсолютные значения  $C(\tau)$  для  $\tau > 1$  малы и с ростом  $\tau$  быстро спадают по абсолютной величине.




Рис. 23: Сверху-вниз: 1) исходный временной ряд, содержащий данные суточного потребления электроэнергии за 2048 рабочих дня; 2) реконструированная (на основе 530 коэффициентов) регулярная составляющая временного ряда; 3) исключенная из исходного ряда высокочастотная (шумовая) компонента

На рис. 23 представлены (сверху-вниз): 1) исходный временной ряд, содержащий данные суточного потребления электроэнергии за первые 2048 рабочих дня (из полного ряда в 3654 рабочих дня); 2) указанный ряд после применения к нему вейвлет-фильтрации (оставлено 530 коэффициентов из 2048); 3) исключенная из исходного ряда высокочастотная (шумовая) компонента.

На рис. 24 приведено распределение шумовой компоненты с результатом проверки соответствия наблюдаемой случайной величины нормальному распределению с помощью критерия согласия  $\chi^2$  [102]. Процедура фитирования проводилась с помощью пакета MINUIT [103] в среде PAW (Physical Analysis Workstation) [104]. Учитывая то, что






Рис. 24: Распределение шумовой компоненты: нижний ряд на рис. 23

реализации шумовой компоненты близки к гауссовскому закону и симметричны относительно нуля (см. рис. 24), можно предположить, что отбрасываемый ряд представляет собой белый гауссовский шум (см., например, [42]).

### 3.2 Структура ИНС, используемой для прогнозирования энергопотребления в Московской агломерации

В работе [127] для прогнозирования энергопотребления в Московской агломерации использовался многослойный перцептрон из пакета TMVA 4.2.0 [92] в среде ROOT [93]. Структура сети была следующей: 5 нейронов на входе, первый скрытый слой содержал 5 нейронов, второй - также 5 нейронов, один выходной нейрон. В результате проведенного анализа для обучения был взят метод kBFGS (смотри, например, [92, 94]), обеспечивший наилучшие результаты как на этапе обучения, так и при тестировании ИНС. Процедура обучения обычно состояла из 1000 эпох.

Набор входных данных включал следующие переменные: 1) год, 2) месяц, 3) день недели, 4) “подсказка” для ИНС, которая бралась либо из отфильтрованного ряда анализируемых данных (на этапе обу-

чения сети), либо из прогнозных значений, вычисленных с помощью пакета “Гусеница”-SSA [42] (на этапе тестирования сети); 5) значение, взятое из исходного ряда (на этапе обучения сети), либо прогнозное на текущий день обученной ИНС (на этапе тестирования сети). Из вышеизложенного следует, что мы перешли от МСП к нейронной сети рекуррентного типа.

Для вычисления прогнозного участка файла-“подсказка”, используемого на этапе проведения среднесрочного прогноза с помощью обученной ИНС, мы применили метод “Гусеница”-SSA, развитый в работах [42, 43, 44]. Детали указанного метода изложены в следующем разделе.

### 3.3 Базовый алгоритм метода “Гусеница”-SSA

Метод “Гусеница”-SSA, развитый в работах [109, 110, 44], может быть применен для анализа вещественнозначного временного ряда  $F$ , отвечающего произвольной функции  $f(t)$ ,  $t > 0$ , определенной на равномерной сетке (в равноудаленных) точках):

$$f_i = f[t_i] = f(i\Delta t), \quad i = 0, 1, \dots, N - 1, \quad (61)$$

где  $\Delta t$  временной интервал, в нашем случае, равный 1.

На начальном этапе выполняется преобразование временного ряда (61) в траекторную матрицу [44, 45]. Затем проводится сингулярное разложение этой матрицы, анализ результатов ее разложения с помощью метода главных компонент и отбор тех компонентов, которые могут представлять интерес для исследователя. При этом (несмотря на проведенную ранее вейвлет-фильтрацию исходного ряда) отбрасываемые компоненты также ответственны за высокочастотную составляющую анализируемого временного ряда. На заключительной стадии проводится реконструкция одномерного временного ряда на основе отобранных компонентов.

Базовый алгоритм метода “Гусеница”-SSA состоит из двух дополняющих друг-друга этапов: 1) разложения и 2) восстановления [44, 45].

#### 3.3.1 Первый этап: разложение

##### Шаг 1: Вложение

Процедура вложения переводит исходный временной ряд (61) в последовательность многомерных векторов. Она представляет собой стандартную процедуру анализа временных рядов (см., например, [109]).

Пусть  $L$  – некоторое целое число (длина окна),  $1 < L < N$ . Тогда  $L$ -траекторная матрица ряда  $F$  – это матрица следующего вида

$$\mathbf{X} = (x_{ij})_{i,j=1}^{L,K} = \begin{pmatrix} f_0 & f_1 & f_2 & \dots & f_{K-1} \\ f_1 & f_2 & f_3 & \dots & f_K \\ f_2 & f_3 & f_4 & \dots & f_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_{L-1} & f_L & f_{L+1} & \dots & f_{N-1} \end{pmatrix}. \quad (62)$$

Таким образом, процедура вложения образует  $K = N - L + 1$  векторов вложения

$$\mathbf{X} = [X_1 : \dots : X_K]$$

из столбцов траекторной матрицы (62)

$$X_i = (f_{i-1}, \dots, f_{i+L-2})^T, \quad 1 \leq i \leq K,$$

имеющих размерность  $L$ .

Заметим, что в нашем случае величина окна  $L$  будет выбираться достаточно большой, но не более половины длины анализируемого временного ряда. В этом случае, каждый из векторов  $L$ -вложения будет содержать в себе существенную часть поведения исходного ряда  $F = (f_0, \dots, f_{N-1})$ . Результатом такого шага является именно матрица  $\mathbf{X}$ , а не набор ее столбцов (векторов вложения), так как упорядоченность элементов внутри каждого вектора, как и упорядоченность самих векторов, играют ключевую роль в методе “Гусеница”-SSA [45].

## Шаг 2: Сингулярное разложение

Сингулярное разложение является ключевой основой математической части метода. Результатом этого шага является сингулярное разложение ( $SVD = Singular Value Decomposition$ ) траекторной матрицы ряда  $F$ .

Сингулярное разложение произвольной  $L \times K$ -матрицы  $\mathbf{X} = [X_1 : \dots : X_K]$  – это разложение  $\mathbf{X}$  в виде

$$\mathbf{X} = \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T, \quad (63)$$

где  $\lambda_i (i = 1, \dots, L)$  – собственные числа матрицы  $\mathbf{S} = \mathbf{X}\mathbf{X}^T$ , упорядоченные по убыванию,

$$d = \max\{i, \text{таких, что } \lambda_i > 0\} = \text{rank } \mathbf{X},$$

где  $\{U_1, \dots, U_d\}$  – соответствующие системы ортонормированных собственных векторов матрицы  $\mathbf{S}$  и векторов  $V_i = \mathbf{X}^T U_i / \sqrt{\lambda_i}$ .

В стандартной терминологии  $\sqrt{\lambda_i}$  называются *сингулярными числами*, а  $U_i$  и  $V_i$  – *левыми* и *правыми сингулярными векторами* матрицы  $\mathbf{S}$ , соответственно. Набор  $(\sqrt{\lambda_i}, U_i, V_i)$  называется  *$i$ -ой собственной тройкой* матрицы  $\mathbf{X}$ . Так как строки и столбцы траекторной матрицы являются отрезками исходного временного ряда, то левый и правый сингулярные вектора несут в себе привязку ко времени.

Если определить  $\mathbf{X}_i = \sqrt{\lambda_i} U_i V_i^T$ , то разложение (63) может быть переписано в виде

$$\mathbf{X} = \mathbf{X}_1 + \dots + \mathbf{X}_d, \quad (64)$$

т.е. как представление  $\mathbf{X}$  в виде суммы элементарных матриц. При этом собственное число  $\lambda_i$  является характеристикой вклада матрицы  $\mathbf{X}_i$  в разложение (64).

### 3.3.2 Второй этап: восстановление

#### Шаг 3: Группировка

Целью этапа группировки является разделение аддитивных компонент анализируемого ряда. На основе разложения (64) процедура группировки делит все множество индексов  $\{1, \dots, d\}$  на  $m$  непересекающихся подмножеств  $I_1, \dots, I_m$ .

Пусть  $I = \{i_1, \dots, i_p\}$ . Тогда результирующая матрица  $\mathbf{X}_I$ , соответствующая группе  $I$ , определяется как

$$\mathbf{X}_I = \mathbf{X}_{i_1} + \dots + \mathbf{X}_{i_p}.$$

Такие матрицы вычисляются для  $I = I_1, \dots, I_m$ , тем самым разложение (64) может быть записано в сгруппированном виде

$$\mathbf{X} = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m}. \quad (65)$$

Процедура выбора множеств  $I_1, \dots, I_m$  называется группировкой собственных троек.

Для простоты примем  $m = 2$ ,  $I_1 = I = \{i_1, \dots, i_r\}$  и  $I_2 = \{1, \dots, d\} \setminus I$ , где  $1 \leq i_1 < \dots < i_r \leq d$ . Таким образом, мы полагаем, что временной ряд  $F$  равен сумме двух рядов,  $F^{(1)}$  и  $F^{(2)}$ , т.е.,  $f_i = f_i^{(1)} + f_i^{(2)}$  для  $i = 0, \dots, N - 1$ .

Зафиксируем длину окна  $L$  и обозначим через  $\mathbf{X}$ ,  $\mathbf{X}^{(1)}$  и  $\mathbf{X}^{(2)}$  соответствующие  $L$ -траекторные матрицы рядов  $F$ ,  $F^{(1)}$  и  $F^{(2)}$ . Рассмотрим сингулярное разложение (64) траекторной матрицы  $\mathbf{X}$ . Мы будем говорить, что ряды  $F^{(1)}$  и  $F^{(2)}$  (слабо) делимы разложением (64), если существует такой набор индексов  $I \subset \{1, \dots, d\}$ , что  $\mathbf{X}^{(1)} = \sum_{i \in I} \mathbf{X}_i$  и, следовательно,  $\mathbf{X}^{(2)} = \sum_{i \in I^c} \mathbf{X}_i$  [45]. В случае делимости вклад  $\mathbf{X}^{(1)}$ , первой компоненты в разложении  $\mathbf{X} = \mathbf{X}^{(1)} + \mathbf{X}^{(2)}$ , естественно выражается как доля соответствующих собственных чисел:  $\sum_{i \in I} \lambda_i / \sum_{i=1}^L \lambda_i$ .

Заметим, что при описании динамики суточного потребления электроэнергии в Московской агломерации суммой двух рядов ( $m = 2$ ), более естественно говорить не о разделении двух компонентов, а о выделении регулярной составляющей ряда  $F$  и отбрасывании высокочастотного шума.

#### Шаг 4: Диагональное усреднение

На последнем шаге базового алгоритма каждая матрица сгруппированного разложения (65) переводится в новый ряд длины  $N$ .

Пусть  $\mathbf{Y}$  – матрица  $L \times K$  с элементами  $y_{ij}$ ,  $1 \leq i \leq L$ ,  $1 \leq j \leq K$ . Положим  $L^* = \min(L, K)$ ,  $K^* = \max(L, K)$  и  $N = L + K - 1$ . Пусть  $y_{ij}^* = y_{ij}$ , если  $L < K$ , и  $y_{ij}^* = y_{ji}$  иначе.

Диагональное усреднение переводит матрицу  $\mathbf{Y}$  в ряд  $g_0, \dots, g_{N-1}$

по формуле

$$g_k = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m,k-m+2}^* & \text{для } 0 \leq k < L^* - 1, \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+2}^* & \text{для } L^* - 1 \leq k < K^*, \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+2} y_{m,k-m+2}^* & \text{для } K^* - 1 \leq k < N. \end{cases} \quad (66)$$

Выражение (66) соответствует усреднению элементов матрицы вдоль “диагоналей”  $i + j = k + 2$ : выбор  $k = 0$  дает  $g_0 = y_{11}$ , для  $k = 1$   $g_1 = (y_{12} + y_{21})/2$  и т.д.

Применив диагональное усреднение (66) к результирующим матрицам  $\mathbf{X}_{I_k}$ , мы получаем ряды  $\tilde{F}^{(k)} = (\tilde{f}_0^{(k)}, \dots, \tilde{f}_{N-1}^{(k)})$  и, следовательно, исходный ряд  $f_0, \dots, f_{N-1}$  раскладывается в сумму  $m$  рядов:

$$f_n = \sum_{k=1}^m \tilde{f}_n^{(k)}. \quad (67)$$

Заметим, что процедура диагонального усреднения в общем случае должна приводить к улучшению разделимости разных компонентов ряда (65) [45].

### 3.4 Вычисление прогнозной части файла “подсказка”

Для вычисления прогнозной части файла-“подсказка” мы использовали программу CaterpillarSSA (version 3.40, Professional M Edition, см. детали на сайте [111]). Данная версия программы предназначена для анализа и прогноза одномерных и многомерных временных рядов. Она также содержит модуль обнаружения разладки в структуре одномерных временных рядов.

Отметим ключевые моменты, важные с точки зрения вычисления прогнозной части файла-“подсказка”:

1. В качестве входной информации для программы CaterpillarSSA использовался отфильтрованный с помощью вейвлет-фильтрации временной ряд, т.е. ряд, из которого была удалена шумовая компонента.

2. Перед тем, как перейти к многомерному виду, этот ряд был отнормирован (средствами CaterpillarSSA).
3. При переходе к многомерному виду (62) длина гусеницы была взята равной 600, т.к. она: а) должна быть кратной 5 (число дней в неделе, исключая выходные) и 12 (число месяцев в году); б) включать несколько годовых циклов (с тем, чтобы можно было выделить характерные особенности анализируемого ряда).
4. На этапе реконструкции одномерного ряда была оставлена 31 компонента; их общий вклад составил чуть более 95 %;
5. На этапе прогнозирования доверительный интервал был задан равным 0,25.




Рис. 25: Вычисление прогнозной части файла-“подсказка” с помощью программы CaterpillarSSA

На рис. 25 приведены результаты прогнозирования с помощью программы CaterpillarSSA на 120 дней вперед: а) сплошной линией изображен отфильтрованный ряд; б) жирной пунктирной линией представлена прогнозная кривая; в) точками показаны кривые, отвечающие доверительному интервалу.

### 3.5 Прогнозирование энергопотребления в Московском агломерации с помощью рекуррентной ИНС

Перед тем, как приступить к работе с ИНС, перечисленные выше переменные  $1 \div 5$ , (обозначим их через  $z$ ) приводились к диапазону  $[-1; +1]$  с помощью преобразования:

$$x_i = \frac{(z_i - A_i) \cdot 2}{B_i - A_i} - 1, \quad i = 0, 1, \dots, 4, \quad (68)$$

где  $z_i$  – исходное значение переменной  $z$ ,  $A_i$  и  $B_i$  – минимальное и максимальное значения переменной  $z_i$ , а  $x_i$  – значение нормированной переменной.

На рис. 26 приведен график изменения ошибки при обучении ИНС в зависимости от номера эпохи.




Рис. 26: График изменения ошибки при обучении ИНС в зависимости от номера эпохи

После завершения процедуры обучения ИНС и фиксации весов оценивалось качество прогноза по последним 120 наблюдениям.

На рис. 27 представлены фактические объемы потребления электроэнергии (сплошная линия) вместе с прогнозными значениями (пунктирная линия), спрогнозированными ИНС на период в 120 дней.

На рис. 28 приведено распределение относительной ошибки  $R_y$

$$R_y = \frac{y_{real} - y_{prog}}{y_{real}}, \quad (69)$$

где  $y_{real}$  – наблюдаемое (реальное) значение суточного энергопотребления, а  $y_{prog}$  – прогноз, полученный с помощью МСП.






Рис. 27: Фактические и прогнозные ИНС значения объемов потребления электроэнергии




Рис. 28: Распределение относительной ошибки при тестировании обученной сети

На рис. 29 показана кривая зависимости относительной ошибки от порядкового номера дня прогнозирования.

Заметим, что указанная зависимость согласуется с поведением автокорреляционной функции для регулярной составляющей анализируемого ряда: (смотри рис. 22 (справа)).

Из приведенного на рис. 28 распределения видно, что, несмотря на довольно большой промежуток прогнозирования, обученная ИНС

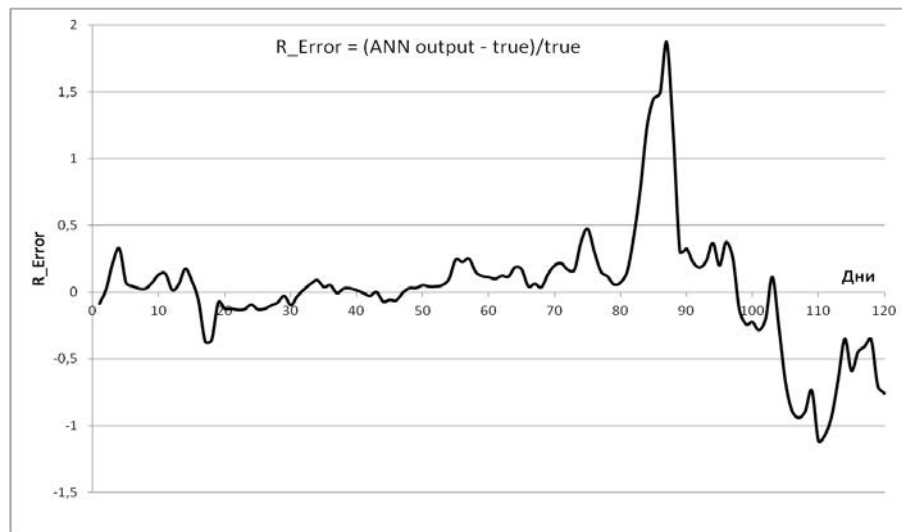


Рис. 29: Зависимость относительной ошибки от порядкового номера дня при прогнозировании с помощью ИНС

обеспечивает прогнозирование суточного энергопотребления в Московской агломерации.

### 3.6 Прогнозирование потребления электроэнергии в Московской агломерации в подходе “Гусеница”-SSA

Для прогнозирования суточного потребления электроэнергии в Московской агломерации использовалась та же версия программы CaterpillarSSA. Все важные параметры, используемые этой программой, совпадали с тем, что отмечалось выше, за исключением того, что при реконструкции одномерного ряда бралась 31 главная компонента. При этом их общий вклад составил 96,89 %.

На рис. 30 приведены графики 16-ти первых компонент разложения исходного ряда потребления электроэнергии в рабочие дни. Из графиков видно, что рассматриваемые компоненты отвечают за трендовые и периодические (сезонные) составляющие анализируемого ряда.

На рис. 31 представлены графики 16-ти компонент с порядковыми номерами выше 31. Учитывая характер поведения указанных компонент, а также их вклад в анализируемый процесс, все компоненты, начиная с 32-ой и выше, на этапе реконструкции анализируемого ряда отбрасывались.

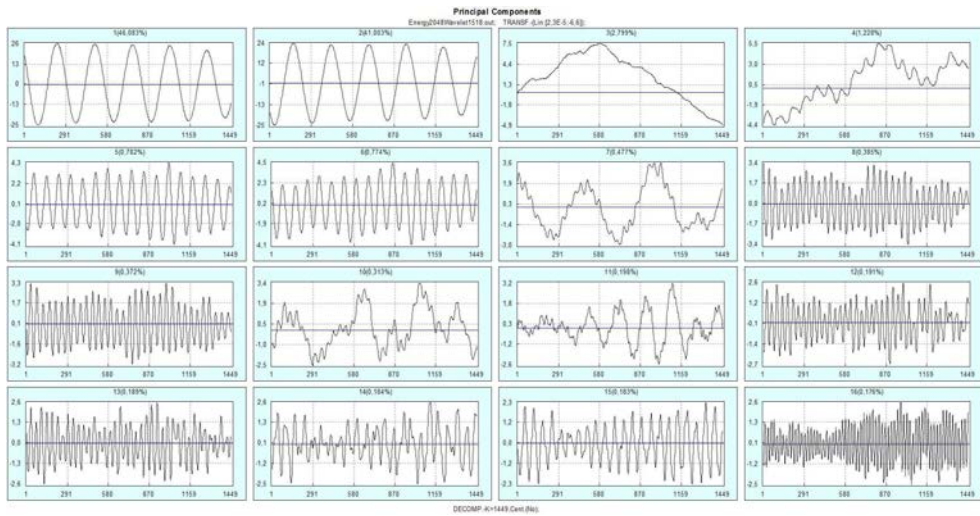


Рис. 30: Графики первых 16-ти компонент

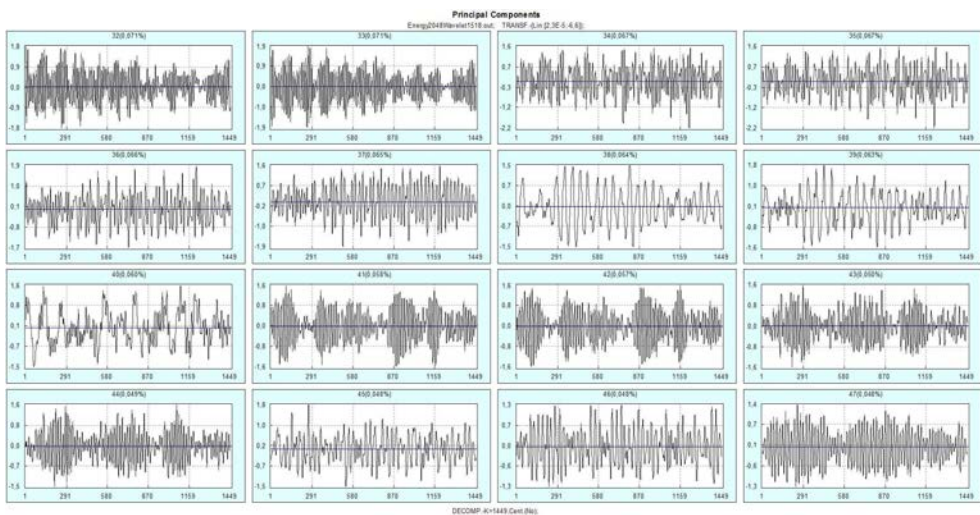


Рис. 31: Графики компонент с 32 по 47

На рис. 32 приведены: 1) вверху – исходный ряд с его аппроксимацией, реконструированной по первым 31 компонентам, 2) внизу – ряд, восстановленный на основе отбрасываемых компонентов.

На рис. 33 представлен PP-plot [112] функций накопленной вероятности для нормального распределения (изображенного отрезком прямой) и для данных, отвечающих отброшенным компонентам. Видно, что отбрасываемые данные согласуются с нормальным распределением, из чего можно предположить, что отвечающий им процесс по своему поведению близок к гауссовскому шуму.

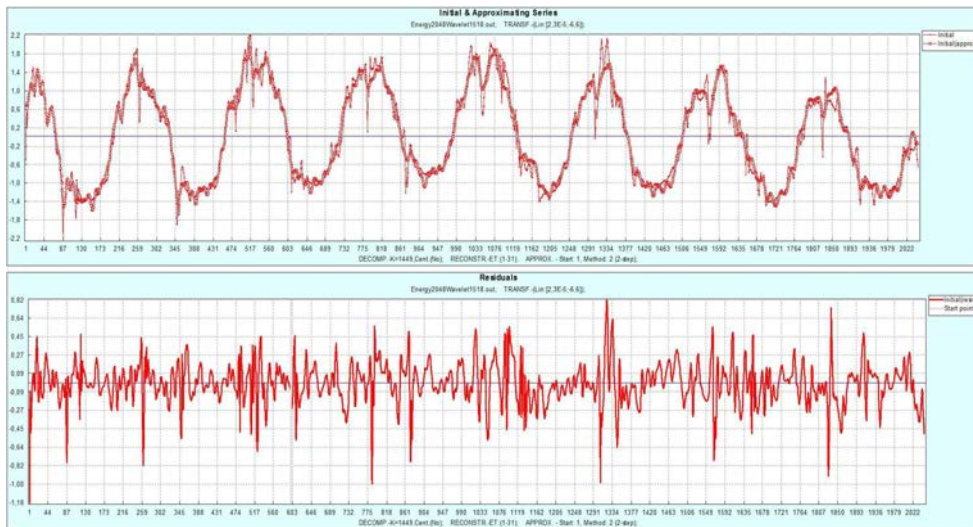


Рис. 32: Вверху – исходный ряд и его аппроксимация, внизу – ряд, отвечающий отбрасываемым компонентам




Рис. 33: Normal-pp-plot распределение, отвечающее отброшенным компонентам

На рис. 34 приводятся результаты прогнозирования суточных объемов потребления электроэнергии на подходе “Гусеница”-SSA. Прогноз делается на период в 120 дней, начиная с 1928 отсчета: на рисунке этот день отмечен вертикальным отрезком. Слева от указанного отрезка изображен участок исходного ряда и его аппроксимация на основе 31 компоненты (см. рис. 32). Справа показана прогнозная кривая вместе с коридором, отвечающему заданному доверительному интервалу. Следует отметить, что на этом рисунке все кривые относятся к стан-

дартизованным данным.




Рис. 34: Фактические и прогнозируемые значения суточных объемов потребления электроэнергии для стандартизованных данных

Очевидно, что удобнее работать с реальными, а не с преобразованными данными. Соответствующие результаты представлены на рис. 35. Фактические объемы потребления электроэнергии (сплошная линия), прогнозные значения (пунктирная линия) показаны в исходных величинах - Мвт\*ч. Точечными линиями показан коридор, отвечающий заданному доверительному интервалу.




Рис. 35: Фактические и прогнозируемые значения суточных объемов потребления электроэнергии на период в 120 дней (в Мвт\*ч)

На следующем рис. 36 показана динамика изменения относитель-

ных ошибок  $R\_err = (Real - Pred)/Real$  (здесь  $Real$  – это фактическое, а  $Pred$  – прогнозное значения объемов потребления электроэнергии) в течение всего периода прогнозирования. На следующем рис. 37 при-




Рис. 36: Динамика относительных ошибок для прогноза на период в 120 дней

ведено распределение относительных ошибок  $R\_err$  на весь период прогнозирования.




Рис. 37: Распределение относительных ошибок для прогноза на период в 120 дней

Из приведенных динамики (рис. 36) и распределения (рис. 37) относительных ошибок при прогнозе на период в 120 дней можно сделать вывод о том, что подход “Гусеница”-SSA позволяет с хорошей точностью проводить среднесрочный прогноз.

При этом следует заметить, что построенные ранее распределение относительной ошибки (рис. 28) и ее зависимость от порядкового номера дня прогнозирования (рис. 29) существенно отличаются от того,

что было получено нами с помощью метода “Гусеница”-SSA (смотри рисунки 37 и 36).

### 3.7 Обсуждение полученных результатов

Проведенный нами анализ показал, что причина указанного расхождения вызвана тем, что при прогнозировании с помощью ИНС использовались данные, которые предварительно приводились к интервалу  $[-1,+1]$ .

Если привести к интервалу  $[-1,+1]$  фактические и прогнозируемые методом “Гусеница”-SSA значения объемов потребления электроэнергии на период в 120 дней, то мы получим зависимости, которые приведены на рис. 36. При этом поведение относительных ошибок при



Рис. 38: Фактические и прогнозируемые значения объемов потребления электроэнергии на период в 120 дней, приведенные к интервалу  $[-1,+1]$

прогнозировании на период в 120 дней приобретает такой же характер, который мы наблюдали в работе [127].

На рис. 40 сведены зависимости относительных ошибок прогнозирования от порядкового номера дня при прогнозе с помощью ИНС (сплошная линия) и метода “Гусеница”-SSA (пунктирная линия).

В дополнение к этим результатам на рис. 41 приведены аналогичные зависимости для исходных данных – не преобразованных к интервалу  $[-1,+1]$ .



Рис. 39: Динамика относительных ошибок при прогнозировании на период в 120 дней



Рис. 40: Зависимости относительных ошибок прогнозирования от порядкового номера дня при прогнозировании с помощью ИНС (сплошная линия) и метода “Гусеница”-SSA (пунктирная линия) для отнормированных данных

Мы видим, что в обоих случаях рассматриваемые зависимости согласуются друг с другом.

### 3.8 Выводы к Главе 3

В работе [127], нами было показано, что проблема среднесрочного прогнозирования суточного потребления электроэнергии в Москов-





Рис. 41: Зависимости относительных ошибок от порядкового номера дня при прогнозировании с помощью ИНС (сплошная линия) и методом “Гусеница”-SSA (пунктирная линия) для данных, не преобразованных к интервалу  $[-1,+1]$

ской агломерации может быть успешно решена с помощью искусственной нейронной сети рекуррентного типа. При этом на этапе прогнозирования обученной ИНС использовались данные прогноза, построенного с помощью метода, реализованного в пакете “Гусеница”-SSA.

В работе [125] нами исследована возможность проведения среднесрочного прогноза суточного потребления электроэнергии в Московской агломерации на основе методики, реализованной в подходе “Гусеница”-SSA. Наши предположения о том, что в этом случае точность прогноза и его горизонт должны несколько уступать тому, что было получено в работе [127], не оправдались. Проведенный анализ показал, что прогнозирование, реализованное на основе методики “Гусеница”-SSA, хорошо согласуется с результатами работы [127].

С учетом результатов, представленных в Главе 3, и методики прогнозирования на основе рекуррентной ИНС, развитой в [127], нами была построена вычислительная схема, позволившая обеспечить успешное прогнозирование пассажиропотока в Московском метрополитене в среднесрочной перспективе. При этом один из ключевых факторов, используемых при прогнозировании пассажиропотока – потребление электроэнергии в Московской агломерации – можно будет предсказывать применяя методику, реализованную в подходе “Гусеница”-SSA.

Указанная вычислительная схема и полученные с ее помощью результаты рассмотрены в Главе 4.

## **4 Прогнозирование пассажирских перевозок в Московском метрополитене на основе совместного использования ИНС и сингулярно-спектрального анализа**

В Главе 4 развита методика и проведена ее опытная апробация для среднесрочного прогнозирования суточных объемов пассажирских перевозок в Московском метрополитене. Она включает три варианта прогноза: 1) на основе искусственной нейронной сети рекуррентного типа; 2) используя сингулярно-спектральный анализ, реализованный в пакете “Гусеница”-SSA; 3) совместное использование ИНС и подхода “Гусеница”-SSA. Нами показано, что разработанная вычислительная схема, методы и алгоритмы позволяют проводить с приемлемой точностью среднесрочное прогнозирование пассажирских перевозок в Московском метрополитене.

### **4.1 Предпосылки и исходные данные для прогнозирования**

Как отмечалось в Главе 2, из всего набора переменных для последующего анализа были отобраны следующие: Var1 (год наблюдения), Var2 (месяц), Var3 (день недели), Var4 (тип дня), Var5 (отклонение дневной температуры от нормы) и Var6 (суточное потребление электрической энергии в Московской агломерации). Причем, как было показано в Главе 3, переменную Var6 (суточное потребление электрической энергии в Московской агломерации) можно с высокой точностью прогнозировать с помощью метода, реализованного в подходе “Гусеница”-SSA [110]÷[45].

Из указанных величин, а также переменной Var7 (суточный объем пассажирских перевозок в ММ) формировались выборки данных, которые использовались нами в Главе 2 для обучения и прогнозирования с помощью МСП. В отличие от Главы 2, в Главе 3 ряд, отвечающий переменной Var7, предварительно подвергался вейвлет-фильтрации [101]. Делалось это для того, чтобы исключить из исходных данных высокочастотную шумовую компоненту, за счет чего (и это было показано нами) можно повысить точность и увеличить горизонт прогнозирования.

ния.

В Главе 3 была разработана вычислительная схема, позволившая успешно решить проблему среднесрочного прогнозирования суточного потребления электроэнергии в Московской агломерации помощью МСП из пакета TMVA 4.2.0 [92], преобразованного в ИНС рекуррентного типа. При этом на этапе прогнозирования с помощью указанной ИНС использовались данные прогноза, построенного с помощью метода, реализованного в подходе “Гусеница”-SSA [110]÷[45].

## 4.2 Прогнозирование пассажирских перевозок с помощью рекуррентной ИНС

Перед тем, как приступить к работе с ИНС, переменные Var1÷Var7 приводились к диапазону [-1;+1] с использованием формулы (68).

Как и ранее, для решения рассматриваемой задачи использовался многослойный перцептрон из пакета TMVA 4.2.0 [92] в среде ROOT [93], преобразованного в ИНС рекуррентного типа. Структура сети была следующей: 7 нейронов на входе, первый скрытый слой содержал 16 нейронов, второй - 8 нейронов, и один выходной нейрон. Для обучения сети использовалась выборка, включающая в зависимости от горизонта прогнозирования разное количество дней наблюдения: 994 или 974 при прогнозе на 30 или 50 дней, соответственно. Для обучения использовался метод Fletcher-Reeves, обеспечивший наилучшие результаты как на этапе обучения, так и при тестировании ИНС. Процедура обучения включала 1500 эпох. В отличие от экспериментов, результаты которых представлены в Главе 2, каждое прогнозное значение ИНС подавалось обратно на вход ИНС (обеспечение свойства рекуррентности).

На рис. 42 приведен типичный график изменения ошибки при обучении ИНС в зависимости от номера эпохи.

После завершения процедуры обучения ИНС проводилось тестирование обученной сети – оценка качества прогнозирования. На этом этапе в качестве переменной Var7 на вход ИНС подавалось то значение, которое выдавалось сетью в качестве прогноза на предыдущем шаге вычислений.

На рис 43 представлены результаты прогнозирования с помощью




Рис. 42: График изменения ошибки при обучении ИНС в зависимости от номера эпохи  
 ИНС на 30 (слева) и 50 (справа) дней наблюдения в сравнении с реальными данными.




Рис. 43: Результаты прогнозирования с помощью ИНС на 30 (слева) и 50 (справа) дней наблюдения в сравнении с реальными данными

На следующем рис.44 показано поведение относительной ошибки величины  $R_y$  в зависимости от порядкового номера дня наблюдения при прогнозировании на 30 (слева) и 50 (справа) дней.

Ошибка  $R_y$  вычислялась по формуле см. равенство (69) в главе 2.

На рис. 45 приведены гистограммы распределения относительной ошибки  $R_y$  при прогнозировании на 30 (слева) и 50 (справа) наблюдений. Из приведенных на рисунках 44 и 45 результатов видно, что ошибка  $R_y$  распределена симметрично относительно нуля и на всем




Рис. 44: Динамика величины  $R_y$  в зависимости от порядкового номера дня наблюдения при прогнозировании с помощью ИНС на 30 (слева) и 50 (справа) дней




Рис. 45: Распределения переменной  $R_y$  при прогнозировании на 30 (слева) и 50 (справа) дней

интервале прогнозирования она чуть более 3% при прогнозе на 30 дней и не превышает 5% при прогнозе на 50 дней.

Таким образом, используя ИНС можно хорошей точностью проводить среднесрочный прогноз объемов пассажирских перевозок в Московском метрополитене.

### 4.3 Прогнозирование пассажирских перевозок в ММ на основе сингулярно-спектрального анализа (подход “Гусеница”-SSA)

Как отмечалось в Главе 3, проблема среднесрочного прогнозирования суточного потребления электроэнергии в Московской агломерации может быть успешно решена с помощью искусственной нейронной

сети рекуррентного типа. При этом на этапе прогнозирования обученной ИНС использовались данные прогноза, построенного с помощью метода, реализованного в подходе “Гусеница”-SSA [110]÷[45].

Для прогнозирования пассажирских перевозок на основе сингулярно-спектрального анализа использовалась методика и последовательность вычислений, изложенная в Главе 3. На начальном этапе выполнено преобразование временного ряда, описывающего суточный пассажиропоток в метрополитене в траекторную матрицу [44, 45]. Далее проводилось сингулярное разложение этой матрицы, анализ результатов ее разложения с помощью метода главных компонент и отбор тех компонент, которые могут представлять интерес для исследователя. При этом (несмотря на проведенную предварительно вейвлет-фильтрацию исходного ряда) дополнительно отбрасывались компоненты, ответственные за высокочастотную составляющую анализируемого временного ряда. На заключительной стадии проводилась реконструкция одномерного временного ряда на основе отобранных компонент.

Для прогнозирования суточных объемов пассажирских перевозок в Московском метрополитене использовалась последняя версия программы CaterpillarSSA (version 3.40, Professional M Edition [111]). Отметим основные моменты, связанные с прогнозированием суточных объемов пассажирских перевозок в Московском метрополитене с помощью пакета “Гусеница”-SSA:

1. В качестве входной информации для программы CaterpillarSSA использовался отфильтрованный с помощью вейвлет-фильтрации временной ряд, т.е. ряд, из которого предварительно была удалена высокочастотная шумовая компонента (см. подробное описание метода в Главе 2); перед тем, как проводить преобразование к многомерному виду (62), анализируемый временной ряд был стандартизован средствами CaterpillarSSA [111].
2. При переходе к многомерному виду (62) длина гусеницы бралась равной 492, что составляет примерно половину анализируемого ряда, позволяя выделить все характерные его особенности.
3. При реконструкции одномерного ряда использовалось 13 главных компонент; их общий вклад составил 99,91%.

4. На этапе прогнозирования доверительный интервал был задан равным 0,25.

На рис. 46 приведены графики 13-ти первых компонент разложения анализируемого ряда при прогнозировании на 30 дней наблюдения. Из графиков видно, что рассматриваемые компоненты отвечают

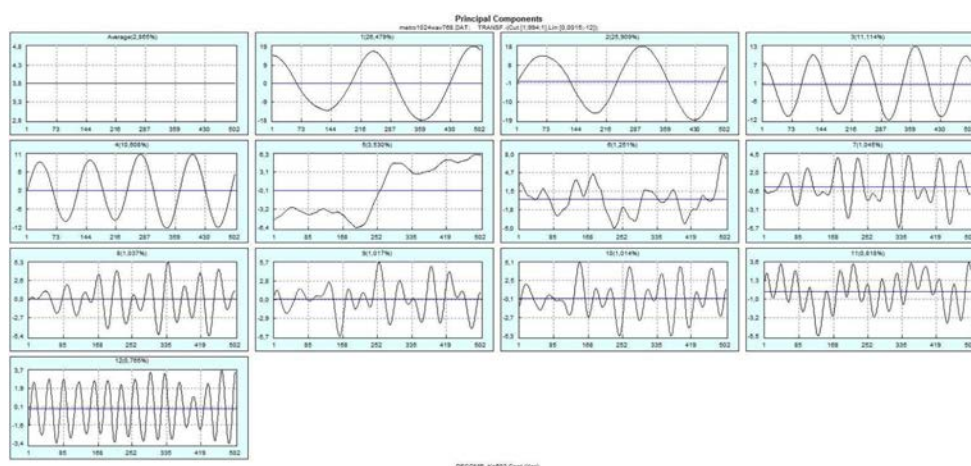


Рис. 46: Графики 13-ти первых компонентов при прогнозировании на 30 дней

за трендовую и периодические (сезонные) составляющие анализируемого ряда.

На рис. 47 приведены: 1) вверху – исходный ряд с его аппроксимацией, реконструированной по первым 13 компонентам, 2) внизу – ряд, восстановленный на основе отбрасываемых компонентов.

На рис. 48 представлен PP-plot [112], [113], [114] функций накопленной вероятности для нормального распределения (изображенного отрезком прямой) и для данных, отвечающих отброшенным компонентам. Видно, что отбрасываемые данные согласуются с нормальным распределением, из чего можно предположить, что отвечающий им процесс по своему поведению близок к гауссовскому шуму.

Заметим, что графики, представленные на рисунках 46, 47 и 48, отвечают прогнозу на 30 дней наблюдения. Аналогичные графики для прогноза на 50 дней наблюдения имеют схожий характер.

На рис 49 представлены результаты прогнозирования в подходе “Гусеница”-SSA на 30 (слева) и 50 (справа) дней наблюдения в сравнении с реальными данными.






Рис. 47: Вверху – исходный ряд и его аппроксимация, внизу – ряд, отвечающий отбрасываемым компонентам




Рис. 48: Normal-pp-plot распределение, отвечающее отброшенным компонентам

На рис. 50 показана динамика величины  $R_y$  в зависимости от порядкового номера дня наблюдения при прогнозировании на основе метода, реализованного в “Гусеница”-SSA на 30 (слева) и 50 (справа) дней наблюдения. На следующем рисунке приведены распределения относительной ошибки  $R_y$  при прогнозировании в подходе “Гусеница”-SSA на 30 (слева) и 50 (справа) наблюдений. Из представленных на рисунках




Рис. 49: Результаты прогнозирования в подходе “Гусеница”-SSA на 30 (слева) и 50 (справа) дней наблюдения в сравнении с реальными данными

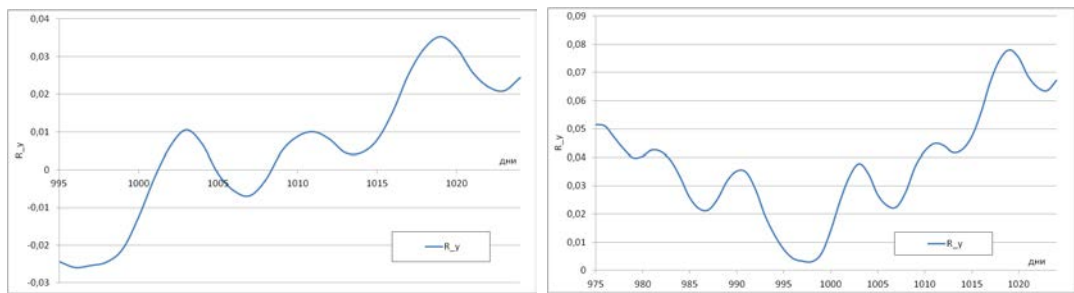


Рис. 50: Динамика величины  $R_y$  в зависимости от порядкового номера дня наблюдения при прогнозировании на основе метода, реализованного в “Гусеница”-SSA на 30 (слева) и 50 (справа) наблюдений




Рис. 51: Распределения переменной  $R_y$  при прогнозировании в подходе “Гусеница”-SSA на 30 (слева) и 50 (справа) наблюдений

50 и 51 результатов видно, что среднее значение ошибки  $R_y$  смещено относительно нуля в область положительных значений. При этом на всем интервале прогноза она не превышает 3% при прогнозировании на 30 дней наблюдения и приближается к 8% при прогнозировании на

50 дней наблюдения.

Приведенные результаты показывают, что хотя нам не удалось добиться точности прогнозирования, достигнутой с помощью ИНС, тем не менее метод, реализованный в подходе “Гусеница”-SSA, позволяет проводить среднесрочный прогноз объемов пассажирских перевозок в Московском метрополитене с приемлемой точностью.

#### 4.4 Сравнительный анализ результатов, полученных разными методами

Как отмечалось выше, при прогнозировании суточных объемов пассажирских перевозок в Московском с помощью ИНС рекуррентного типа на вход сети подавался набор переменных (Var1÷Var7). При этом очевидно, что для проведения такого прогноза нужно было предварительно решить задачи, связанные с прогнозированием двух переменных: Var5 (отклонение дневной температуры от нормы) и Var6 (суточное потребление электрической энергии в Московской агломерации). Задача прогнозирования переменной Var6 была успешно решена в Главе 3, однако вопрос с прогнозом переменной Var5 оставался открытым. В этой связи, мы провели анализ того, как указанная переменная влияет на результаты прогнозирования с помощью ИНС.

На рисунках 52 и 53 представлены сравнительные результаты прогнозирования используя развитые в настоящей работе подходы на 30 и 50 дней наблюдения, в том числе, с учетом и без учета вклада переменной Var5.

На этих рисунках приведены следующие графики: R) прогнозируемый ряд в исходных величинах – сплошная линия серого цвета; RF) прогнозируемый ряд, из которого с помощью вейвлет-фильтрации был удален высокочастотный шум, – сплошная жирная линия; F1) прогноз помощью МСП (без использования SSA-прогноза в качестве “подсказки”) – двойная пунктирная линия; F2) прогноз с помощью SSA – жирная пунктирная линия; F3) прогноз помощью МСП с использованием SSA-прогноза в качестве “подсказки” и без учета вклада переменной Var5 – двойная сплошная линия; F4) прогноз помощью МСП с включением SSA-прогноза в качестве “подсказки”, но без учета вклада переменной Var5 – штрих-пунктирная линия; F5) усредненный прогноз




Рис. 52: Сравнительные результаты прогнозирования на 30 дней наблюдения, используя развитые в настоящей работе подходы

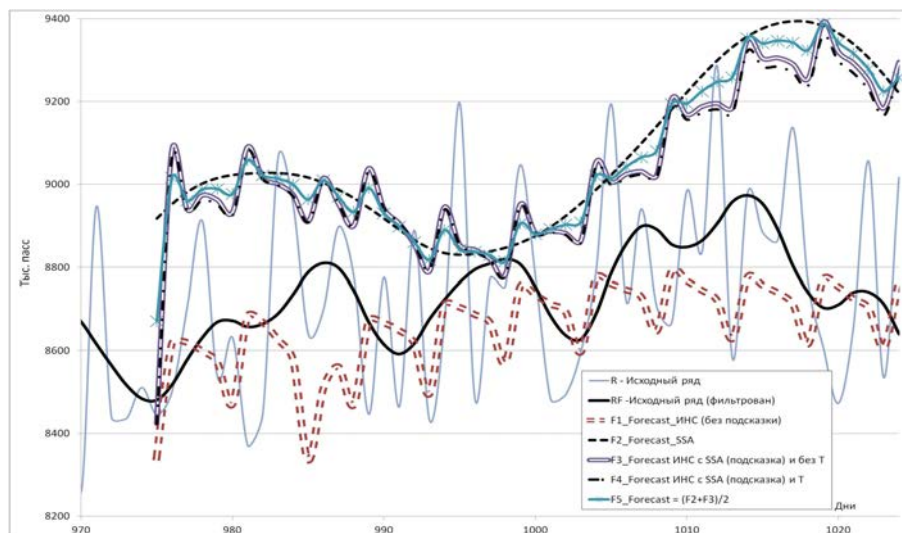


Рис. 53: Сравнительные результаты прогнозирования на 50 дней наблюдения, используя развитые в настоящей работе подходы

$(F2 + F3)/2$  – сплошная линия с крестиками.

Анализ приведенных графиков позволяет сделать ряд выводов:

- наилучший вариант прогноза достигнут с помощью ИНС (без использования SSA-“подсказки”);
- исключение переменной Var5 из набора входных данных для ИНС не оказало заметного влияния на результат прогноза; небольшое

отличие на графиках F3 и F4 можно увидеть только при прогнозе на 50 дней наблюдения (см. рис. 53);

- прогноз на основе подхода “Гусеница”-SSA оказался смещенным относительно прогнозируемых данных в область больших значений пассажиропотока; при использовании SSA-прогноза в качестве “подсказки” для ИНС это же привело к смещению прогнозных кривых F3 и F4 в область больших значений;
- наряду с двумя рассмотренными вариантами прогноза (ИНС и SSA) для надежности целесообразно использовать усредненный прогноз:  $(F2 + F3)/2$ .

#### 4.5 Выводы к Главе 4

В настоящей главе разработана методика для среднесрочного прогнозирования суточных объемов пассажирских перевозок в Московском метрополитене, включающая три разных варианта прогноза: 1) на основе искусственных нейронных сетей; 2) используя сингулярно-спектральный анализ, реализованный в подходе “Гусеница”-SSA; 3) совместное использование ИНС и подхода “Гусеница”-SSA. Показано, что развитые методы и алгоритмы позволяют с приемлемой точностью проводить среднесрочное прогнозирование пассажиропотока на ММ.

Наилучшего варианта прогноза удалось добиться с помощью ИНС рекуррентного типа, на вход которой подавался набор факторов, влияющих на суточные объемы пассажирских перевозок в ММ. Проведенный анализ показал, что из указанного набора можно исключить один из факторов, а именно, отклонение дневной температуры от среднестатистической нормы, т.к. данный фактор не оказывает заметного влияния на результаты прогноза.

Прогноз, построенный на основе сингулярно-спектрального анализа, реализованного в пакете “Гусеница”-SSA, и при котором использовались только данные суточных объемов перевозок пассажиров в ММ, оказался смещенным относительно прогнозируемых данных в область больших значений пассажиропотока. Это же явилось причиной смещения прогнозных значений в область больших величин объемов

перевозок пассажиров при совместном использования методов ИНС и SSA.

Развитая методика среднесрочного прогнозирования с достигнутой в настоящей работе точностью будет способствовать повышению эффективности и скорости принятия управленческих решений в зависимости от ситуации как на метрополитене, так и в окружающей его внешней среде, включая климатические условия и динамику энергопотребления как индикатора промышленной, деловой и социальной активности населения региона, который использует метрополитен как один из основных видов транспорта. Это создаст необходимые условия для выработки предприятиями городского пассажирского транспорта эффективных стратегий и оперативных мер, исходя из прогнозируемых объемов пассажиропотока в ММ, в том числе: 1) определения количества необходимого подвижного состав для перевозки пассажиров; 2) закупки электрической энергии для тяги поездов; 3) подготовки и проведения специальных акций по привлечению пассажиров в определённые временные интервалы,; 4) принятию решений о необходимости увеличения на определенных участках транспортной сети обслуживающего персонала и сотрудников метрополитена; 5) краткосрочного планирования различного рода мероприятий и др.

## Заключение

В диссертационной работе развиты новые математические модели, методы, алгоритмы и комплексы программ, предназначенные для прогнозирования изменений объемов пассажирских перевозок (на примере Московского метрополитена) в зависимости от влияющих факторов, в том числе такого ключевого фактора выступающего в качестве оценки изменений социальной и экономической активности населения - потребление электрической энергии в Московской агломерации. В настоящей работе развиты:

1. Математические модели для оценки изменений объемов пассажирских перевозок (на примере анализа временных рядов суточных объемов перевозок пассажиров в ММ) в зависимости от различных внешних факторов, в том числе от одного из основных показателей социальной и экономической активности населения в рассматриваемом регионе – потребления электрической энергии в Московской агломерации.
2. Комплекс математических методов и соответствующих вычислительных алгоритмов для краткосрочного и среднесрочного прогнозирования изменений объемов пассажирских перевозок (на примере суточных объемов пассажирских перевозок Московским метрополитеном и факторов, влияющих на объемы перевозок) на основе многослойной нейронной сети прямого типа (МСП).
3. Методика применения дискретного вейвлет-преобразования (ДВП) к анализируемым временным рядам, описывающим: а) изменения объемов пассажирских перевозок (на примере временных рядов суточных объемов перевозок пассажиров метрополитеном); б) суточное потребление электрической энергии в качестве одного из значимых факторов, влияющих на суточные объемы перевозок пассажиров (на примере конкретного региона). Рассматриваемые временные ряды представляются виде регулярного процесса и стохастической составляющей, играющей роль высокочастотного шума. Исключение из указанных рядов шумовой компоненты позволяет повысить точность прогнозирования и увеличить пер-

спективу прогноза.

4. Математические методы и вычислительные алгоритмы для среднесрочного прогнозирования суточного потребления электрической энергии (на примере конкретного региона) на основе многослойной нейронной сети рекуррентного типа и сингулярно-спектрального анализа с использованием пакета “Гусеница”-SSA.
5. Методика комплексного и совместного применения ДВП, МСП, ИНС рекуррентного типа и сингулярно-спектрального анализа (пакет “Гусеница”) для проведения краткосрочного и среднесрочного прогнозирования изменения объемов перевозки пассажиров Московским метрополитеном с учетом потребления электрической энергии в рассматриваемом регионе или агломерации.

### **Научная новизна полученных результатов**

1. Разработан новый подход для прогнозирования суточных объемов пассажирских перевозок в Московском метрополитене на основе искусственных нейронных сетей (ИНС) прямого типа. Демонстрирована возможность краткосрочного прогнозирования на данных, отвечающих суточным объемам пассажирских перевозок в будние дни.
2. Проведен анализ состава и влияния различных факторов на исследуемые временные ряды. В результате проведенного анализа удалось сократить объем выборки, подаваемой на вход нейронной сети, а также ускорить процедуру ее обучения.
3. Разработана процедура исключения шума на основе вейвлет-фильтрации исходных данных. Показано, что данная процедура позволяет повысить точность прогноза и, как следствие, увеличить горизонт прогнозирования.
4. Развита вычислительная схема (на основе ИНС рекуррентного типа и подхода “Гусеница”-SSA), позволившая обеспечить прогнозирование потребления электроэнергии в Московской агломерации в среднесрочной перспективе.



5. Впервые создана вычислительная схема (на основе ИНС рекуррентного типа и подхода “Гусеница”-SSA), позволившая обеспечить прогнозирование пассажиропотока в Московском метрополитене в среднесрочной перспективе. При этом один из ключевых факторов, используемых при прогнозировании пассажиропотока, выступает потребление электроэнергии в Московской агломерации, которое в свою очередь можно спрогнозировать, применяя методику, реализованную в подходе “Гусеница”-SSA.

### **Практическая ценность**

Развитые в настоящей работе методики для среднесрочного прогнозирования объемов пассажирских перевозок Московским метрополитеном с достигнутой нами точностью могут способствовать повышению эффективности и скорости принятия управленческих решений в зависимости от ситуации как на метрополитене, так и в окружающей внешней среде, включая климатические условия и динамику энергопотребления, как индикатора экономической, деловой и социальной активности населения агломерации или региона, который использует метрополитен в качестве одного из основных видов транспорта.

Данная методика позволяет создать необходимые условия для выработки предприятиями городского пассажирского транспорта эффективных стратегий и оперативных мер, исходя из прогнозируемых суточных объемов пассажиропотока в Московском метрополитене, в том числе: 1) определения количества необходимого подвижного состава для перевозки пассажиров; 2) закупки электрической энергии для тяги поездов; 3) подготовки и проведения специальных акций по привлечению пассажиров в определённые временные интервалы; 4) принятия решений о необходимости увеличения на определенных участках транспортной сети обслуживающего персонала и сотрудников метрополитена; 5) планирования различного рода мероприятий и др.

## **Достоверность результатов**

Достоверность и обоснованность результатов, полученных в диссертации, подтверждены применением для моделирования исследуемых процессов широко известных программ и моделей: программный пакет Statistical Package for the Social Sciences (SPSS), программный пакет Statistica (Statsoft/Dell), пакет MINUIT в среде графического пакета PAW (Physical AnalysisWorkstation), пакет TMVA 4.2.0 в среде ROOT, программа CaterpillarSSA (version 3.40, Professional M Edition).

## **Представление основных положений и результатов**

Основные положения и результаты работы докладывались и обсуждались на международных и российских конференциях и совещаниях, в том числе:

- International Conference on Mathematical Modeling and Computational Physics (ММСР'17) (Дубна, Россия, 2017);
- Всероссийская конференция с международным участием “Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем”, Российский университет дружбы народов (РУДН) (Москва, Россия, 2017).
- Научные семинары Лаборатории информационных технологий Объединенного института ядерных исследований (ЛИТ, ОИЯИ, Дубна, Россия, 2016, 2017);
- Научный семинар кафедры Прикладной математики Национального исследовательского ядерного университета “МИФИ” (Москва, Россия, 2018);
- Научный семинар Российского университета дружбы народов (РУДН) (Москва, Россия, 2018).

## **Публикации**

Все основные результаты диссертации опубликованы в 9 научных трудах, из которых восемь статей опубликованы в рецензируемых изданиях:

- Applied Mathematical Sciences [121].
- “Экономический анализ: теория и практика” [122].
- Вестник Национального исследовательского ядерного университета “МИФИ” // “Математическое и компьютерное моделирование” [123], [124].
- Вестник Национального исследовательского ядерного университета “МИФИ” // “Прикладная математика и информатика” [125].
- Письма в журнал “Физика элементарных частиц и атомного ядра” (“Письма в ЭЧАЯ”) [127], [129].
- European Physics Journal [128].
- Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем [126].

В том числе публикации по материалам и результатам международных конференций и семинаров [126], [127], [128].

### **Личный вклад автора**

Основные положения и результаты, представленные в диссертации, получены при определяющем участии соискателя. Программная реализация разработанных методов и алгоритмов выполнена лично соискателем.

### **Благодарности**

В заключение выражаю благодарность своему научному руководителю Виктору Владимировичу Иванову за постановку задачи, постоянную помощь и поддержку.

Выражаю свою признательность профессору Кряневу Александру Витальевичу за участие в совместных исследованиях, полезные обсуждения и советы.

Я очень благодарен своему другу и коллеге Иванову Валерию Викторовичу за полезные рекомендации, советы и помощь, приведшие в

итоге к подготовке и защите рассматриваемой диссертационной работы.

Я искренне благодарен своим родителям Осетрову Сергею Борисовичу и Осетровой Наталии Яковлевне за неоценимую помощь и поддержку.

Отдельно хочу поблагодарить дирекцию Лаборатории информационных технологий Объединенного института ядерных исследований за хорошие условия для работы, а также за предоставленные возможности для международного сотрудничества и обмена знаниями.

## Список литературы

- [1] Друкер П. Эффективное управление. Экономические задачи и оптимальные решения. М.: ФАИР-Пресс, 1988.
- [2] Беркинблит М. Б. Нейронные сети. — М.: МИРОС и ВЗМШ РАО, 1993. — 96 с. — ISBN 5-7084-0026-9.
- [3] Вороновский Г. К., Махотило К. В., Петрашев С. Н., Сергеев С. А. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности. — Харьков: Основа, 1997. — 112 с. — ISBN 5-7768-0293-8.
- [4] Голубев Ю. Ф. Нейросетевые методы в мехатронике. — М.: Изд-во Моск. унта, 2007. — 157 с. — ISBN 978-5-211-05434-9.
- [5] Горбань А.Н. Обучение нейронных сетей. — М.: СССР-США СП «Параграф», 1990. — 160 с.
- [6] Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. — Новосибирск: Наука, 1996. — 276 с. — ISBN 5-02-031196-0.
- [7] Горбань А. Н., Дунин-Барковский В. Л. и др. Нейроинформатика. — Новосибирск: Наука, 1998.
- [8] Еремин Д.М., Гарцеев И.Б. Искусственные нейронные сети в интеллектуальных системах управления. — М.: МИРЭА, 2004. — 75 с. — ISBN 5-7339-0423-2.
- [9] Каллан Р. Основные концепции нейронных сетей - The Essence of Neural Networks First Edition. — М.: Вильямс, 2001. — 288 с. — ISBN 5-8459-0210-X.
- [10] Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. — М.: Горячая линия - Телеком, 2001. — 382 с. — ISBN 5-93517-031-0.
- [11] Миркес Е.М. Нейрокомпьютер. Проект стандарта. — Новосибирск: Наука, 1999. — 337 с. — ISBN 5-02-031409-9. Другие копии онлайн: Нейрокомпьютер. Проект стандарта.

- [12] Осовский С. Нейронные сети для обработки информации - Sieci neuronowe do przetwarzania informacji (польск.) / Перевод И. Д. Рудинского. — М.: Финансы и статистика, 2004. — 344 с. — ISBN 5-279-02567-4.
- [13] Савельев А.В. На пути к общей теории нейросетей. К вопросу о сложности // Нейрокомпьютеры: разработка, применение. — 2006. — № 4—5. — С. 4—14.
- [14] Сигеру Омату, Марзуки Халид, Рубия Юсоф. Нейроуправление и его приложения - Neuro-Control and its Applications. 2-е изд. — М.: ИПРЖР, 2000. — 272 с. — ISBN 5-93108-006-6.
- [15] Тадеусевич Рышард, Боровик Барбара, Гончаж Томаш, Леппер Бартош. Элементарное введение в технологию нейронных сетей с примерами программ / Перевод И. Д. Рудинского. — М.:
- [16] Терехов В.А., Ефимов Д.В., Тюкин И.Ю. Нейросетевые системы управления. — М.: Высшая школа, 2002. — 184 с. — ISBN 5-06-004094-1.
- [17] Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика = Neural Computing. Theory and Practice. — М.: Мир, 1992. — 240 с. — ISBN 5-03-002115-9.
- [18] Хайкин С. Нейронные сети: полный курс = Neural Networks: A Comprehensive Foundation. 2-е изд. — М.: Вильямс, 2006. — 1104 с. — ISBN 0-13-273350-1.
- [19] Пронин С.В. Применение искусственных нейронных сетей для моделирования транспортных систем // Автомобильный транспорт. 2006. №18.
- [20] Dr. Murat Cuhadar, Iclal Cogurcu, Ceyda Kukrer Modelling and Forecasting Cruise Tourism Demand to Izmir by Different Artificial Neural Network Architectures // International Journal of Business and Social Research. 2014. Volume -4, №.-3,. pp. 12-28.
- [21] K.S. Swarnalatha, G.N.Srinivasan, K. Kiran K. A Roadmap on Design Models for Dynamic Traffic Prediction using Multi-Layer Perceptron

- Networks // International Journal of Scientific Engineering and Technology Research. 2014. №Volume.03, Issue №.16. pp. 3284-3288.
- [22] Глушков, С.В. Построение нечеткой нейросетевой модели информационной системы управления транспортно-логистическим процессом / С.В. Глушков, Н.Г. Левченко, Ю.Ю. Почесуева, Е.М. Коньков. // Вестник государственного университета морского и речного флота имени адмирала С.О. Макарова. – СПб.: ГУМРФ имени адмирала С.О. Макарова, 2013.– Вып. 3, С. 100–111.
- [23] Glushkov, S., Levchenko, N. Use of Neural Network Technologies for Improving Efficiency of Transport and Logistics Processes / N. Levchenko, S. Glushkov // Asia-Pacific Journal of Marine Science Education, Vol. 3, №1, 2013, pp 67–74.
- [24] Барский, А.Б., Нейросетевые технологии на транспорте. / А.Б. Барский // Мир транспорта, 2011, № 2. – С. 4–11.
- [25] Барский, А.Б., Нейросетевые технологии на транспорте. / А.Б. Барский // Мир транспорта, 2011, № 3. – С. 14–19.
- [26] Rodrigue J.P. Parallel Distributed Processing of Transportation / Land Use Systems: Theory and Modelling with Neural Networks // Transportation Research. 1997, Vol. 5, pp. 259-271.
- [27] Smith, B.L., Demetsky M.J. Short-term traffic flow prediction: Neural network approach, Transportation Research Record 1453, 1994, pp. 98-104.
- [28] Vlahogianni E.I., Golias J.C., Karlaftis M.G. Short-term traffic forecasting: Overview of objectives and methods, Transport reviews, Vol. 24, №. 5, 2005. pp. 533-557.
- [29] Dougherty M. A review of neural networks applied to transport. Transportation Research Part C: Emerging Technologies, vol. 3, №. 4, 1995, pp. 247-260.
- [30] Ledoux C. An urban traffic flow model integrating neural networks, Transportation Research Part C: Emerging Technologies, vol. 5, №. 5, 1997, pp. 287-300.

- [31] Yin H., Wong SC., Xu J., Wong CK. Urban traffic flow prediction using a fuzzy-neural approach *Transportation Research Part C: Emerging Technologies*, vol. 10, №. 2, 2002. pp. 85-98.
- [32] Zhejun G. Estimating the urban OD matrix: A neural network approach, *European Journal of Operational Research*, vol. 106, № 1, pp. 1998, pp. 108-115.
- [33] Апатцев В.И., Лысиков М.Г., Ольшанский А.М. Особенности применения нейронных сетей при моделировании перевозочного процесса // *Наука и техника транспорта*. 2014. №3. С. 52-55.
- [34] Ali Payidar Akgungor, Erdem Dogan, Tolga Gurbus Estimation of Highway Transportation Demand in Turkey By Artificial Neural Networks // *Technology*. 2009. №2(3). pp. 217-225.
- [35] Nam, K. and Schaefer, T. (1995), "Forecasting International Airline Passenger Traffic Using Neural Networks," *Logistics and Transportation Review*, 31(3). pp. 239-252.
- [36] Robert L. Cook, Lawrence O. Jenicke, Brian Gibson Using artificial neural networks for transport decisions // *Journal of Transportation Management*. 2010. Fall. pp. 18-32.
- [37] Tsung-Hsien Tsai, Chi-Kang Lee, Chien-Hung Wei Design of dynamic neural networks to forecast short-term railway passenger demand // *Journal of the Eastern Asia Society for Transportation Studies*. 2005. Vol. 6. pp. 1651 - 1666.
- [38] Fu L., Rilett L.R. Estimation of time-dependent, stochastic route travel times using artificial neural networks, *Transportation planning and technology*, 2000. Vol. 24, 25-48.
- [39] Ishak S., Kotha P. and Alecsandru C. Optimization of dynamic neural networks performance for short-term traffic prediction. *Proceedings of the Transportation Research Board 82nd Annual Meeting*, Washington, DC. 2003.
- [40] Claveria O., Monte, E., Torra S. Tourism demand forecasting with different neural networks models, *IREA Working Papers*: 201321,



University of Barcelona, Research Institute of Applied Economics. 2013.

- [41] Zhang G.P., Qi M. Neural network forecasting for seasonal and trend time series, *European Journal of Operational Research*, 160(2), 2005, pp. 502-514.
- [42] Н.Э. Голяндина, В.В. Некруткин, К.А. Браулов: *Метод “Гусеница”-SSA: анализ временных рядов*. Gistat Group, <http://www.gistatgroup.com/gus/>.
- [43] Д.Л. Данилов, А.А. Жиглявский, редакторы: *Главные компоненты временных рядов: метод “Гусеница”*, Изд-во СПбГУ, 1997.
- [44] N. Golyandina, V. Nekrutkin, A. Zhigljavsky: *Analysis of Time Series Structure: SSA and Related Techniques*, Chapman & Hall/CRC, 2001.
- [45] Н.Э. Голяндина, В.В. Некруткин, К.А. Браулов: *Метод “Гусеница”-SSA: анализ временных рядов*, Gistat Group, <http://www.gistatgroup.com/gus>, 13 августа 2002 года.
- [46] Дроздов Б.В. Направления разработки физической экономики (применительно к транспортному комплексу) // Устойчивое инновационное развитие: проектирование и управление. 2014. №2(23).
- [47] Борисов В. Н. Микроэкономика: В 5-х т. / Общ. ред. Чеплянского Ю. В.. — СПб.: Экономическая школа, 2015. — Т. 7, с. 1168—1169, 1171.
- [48] Артыкова С.Н. Показатели транспортной подвижности населения в сегменте «дальнее следование» // Транспортная система мира. 2011.
- [49] Carrothers G. A. P. An historical review of the gravity and potential concepts of human interaction // *J. American Instit. Planners*. 1956. V. 22. P. 94–102.
- [50] Voorhees A. M. A general theory of traffic movement. ITE, 1955.
- [51] Wilson A. G. A statistical theory of spatial distribution models // *Transpn. Res*. 1967. V. 1. P. 253–270.

- [52] Wilson A. G. A family of spatial interaction models and associated developments // *Envir. and Plan. A.* 1971. V. 3. P. 255–282.
- [53] Лившиц В. В. Математическая модель случайно-детерминированного выбора и ее применение для расчета трудовых корреспонденций / Автоматизация процессов градостроительного проектирования. М.: ЦНИИП градостроительства, 1973. С. 39–57.
- [54] Попков Ю. С., Посохин М. В., Гутнов А. Э., Шмульян Б. Л. Системный анализ и проблемы развития городов. М., 1983.
- [55] Айвазян С. А., Бухштабер В. М., Енюков И. С., Мешалкин Л. Д. Прикладная статистика: классификация и снижение размерности. — М.: Финансы и статистика, 1989.
- [56] Hastie, T., Tibshirani, R., Friedman, J. *The Elements of Statistical Learning*, 2nd edition. — Springer, 2009. — 533 p.
- [57] David W. Hosmer, Stanley Lemeshow. *Applied Logistic Regression*, 2nd ed. New York, Chichester, Wiley. 2002. 392 P. ISBN 0-471-35632-8.
- [58] Никулин М. С. Отношения правдоподобия критерий // Математическая энциклопедия / Виноградов И. М. (гл. ред.). — М.: Советская энциклопедия, 1984. — Т. 4. — С. 151. — 1216 с.
- [59] Bliss C.I. (1934). «The method of probits». *Science* 79 (2037): 38–39.
- [60] Finney, D.J. *Probit Analysis* (3rd edition). — Cambridge University Press, Cambridge, UK, 1971. — ISBN 052108041X.
- [61] SNCF International Moscow Saint-Petersburg High Speed Rail // *Premierrfahrt nach Paris*. 2007.
- [62] Кристофер Доугерти. Введение в эконометрику. — 2-е, пер. с англ. — М.: ИНФРА-М, 2004. — 419 с.
- [63] Damodar N. Gujarati. *Basic Econometrics*. — 4. — The McGraw-Hill Companies, 2004. — С. 1002. — ISBN 978-0071123433.

- [64] Айвазян С.А. Прикладная статистика. Основы эконометрики. Том 2. — М.: Юнити-Дана, 2001. — 432 с. — ISBN 5-238-00305-6.
- [65] Орлов А.И. Организационно-экономическое моделирование. М.: МГТУ им. Н.Э. Баумана, 2011.
- [66] Гасников А.В., Кленов С.Л., Нурминский Е.А., Холодов Я.А., и Шамрай Н.Б. Введение в математическое моделирование транспортных потоков. М.: МФТИ, 2010.
- [67] Deutsche Bahn «Прогнозирование перевозок 2015 для федерального плана транспортных магистралей по заказу федерального министерства транспорта, строительства и жилого фонда (FE-№ 96.578/1999)», 2001.
- [68] UK Department for Transport "UK Aviation Forecasts" // <https://www.gov.uk> URL : [https://www.gov.uk/government/uploads/system/uploads/attachment\\_data/file/forecasts.pdf](https://www.gov.uk/government/uploads/system/uploads/attachment_data/file/forecasts.pdf) (дата обращения: 01.02.2015).
- [69] Martin T., Rutherford S. Rail Demand Forecasting in Hong Kong and Shenzhen // <http://www.inrosoftware.com> URL : <http://www.inrosoftware.com/assets/presentation/paper/asian/asi99/paper14.doc>. (дата обращения: 03.02.2015).
- [70] Johnson, N. L., Kotz, S., Balakrishnan N. (1995). Continuous Univariate Distributions. Vol. 2 (2nd Ed. ed.).
- [71] N. Balakrishnan (1992). Handbook of the Logistic Distribution. Marcel Dekker, New York. ISBN 0-8247-8587-8.
- [72] Большаков Б.Е. Теория устойчивого развития и ее применение. Дубна: Международный университет природы и общества и человека «Дубна», 2005.
- [73] Кузнецов П.Г., Образцова Р.И., Пшеничников С.Б. Инженерно-экономический анализ транспортных систем. М.: Радио и связь, 1996.

- [74] Кузнецов О.Л., Кузнецов П.Г., Большаков Б.Е. Система природа—общество—человек: устойчивое развитие. Москва, Дубна: 2000.
- [75] Кузнецов П.Г. О введении системы сетевого планирования и управления на комплекс работ по созданию сложного объекта. М.: МГПИ им. В.И. Ленина, 1966, с 12.
- [76] Системный оператор Единой энергетической системы URL: [www.so-ups.ru/index.php?id=1202](http://www.so-ups.ru/index.php?id=1202) (дата обращения: 10.10.2015).
- [77] Московский метрополитен. Официальный сайт. URL: <http://mosmetro.ru/> (дата обращения: 01.09.2015).
- [78] Е.Е. Артемкина: *Методы определения спроса на пассажирские автотransпорты и их значение для эффективной организации системы пассажирского автотранспорта* [Текст] / Е. Е. Артемкина // Актуальные вопросы экономических наук: материалы III международной науч. конф. (г. Уфа, июнь 2014 г.). — Уфа: Лето, 2014. — С. 169-171.
- [79] Н.Н. Правдин. и В.Я. Негрей: *Прогнозирование пассажирских перевозок*, Москва, издательство “Транспорт”. 1980.
- [80] Д.С. Леванова: *Прогнозирование пассажиропотока метрополитена на основе математических моделей*. Автореферат диссертации на соискание ученой степени кандидата технических наук, Санкт-Петербург, 2005.
- [81] Р.С. Кударов: *Математические модели формирования входного потока пассажиропотока станций метрополитена*. Автореферат диссертации на соискание ученой степени кандидата технических наук, Санкт-Петербург, 2009.
- [82] Общая теория статистики: Учебник / Под ред. Р. А. Шмойловой. — 3-е издание, переработанное. — Москва: Финансы и Статистика, 2002. — 560 с. — ISBN 5-279-01951-8.

- [83] И.С. Светуных и С.Г. Светуных: *Методы и модели социально-экономического прогнозирования: учебник и практикум для академического бакалавриата*, Москва, Издательство Юрайт, 2014. — 351 с.
- [84] Frisch R. Statistical Confluence Analysis by means of complete regression systems, Universitetets Okonomiske Institute, 1934.
- [85] Gianfranco Galmacci, Collinearity Detection in Linear Regression. *Computational Economics* 9:215-227, 1996.
- [86] Simon Haykin: *Neural Networks: A comprehensive foundation, 2nd edition*, Prentice Hall, 1999.
- [87] B. Denby: *Tutorial on Neural Networks Applications in High Energy Physics: 1982 Perspective*. In Proc. of the Second International Workshop on “Software Engineering, Artificial Intelligence and Expert System in High Energy Physics”. January 13-18, 1992 L’Agelaude France-Telecom La Londe-les-Maures (France). *New Computing Techniques in Physics Research II*, edited by D.Perret-Gallix, World Scientific, 1992, p.287.
- [88] F. Fogelman Soulie: *Neural Networks for Patterns Recognition: Introduction and Comparison to Other Techniques*, Ibidem, p. 277.
- [89] D.E. Rumelhart, G.E. Hinton, R.J. Williams: *Learning Internal Representations by Error Propagation* in D.E.Rumelhart, J.L.McClelland (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. vol.1: Foundations. MIT Press, 1986.
- [90] G. Cybenko: *Approximation by Superposition of a Sigmoidal Function*, *Math. Control Signals Systems*, **2** (1989) 303.
- [91] C. Peterson, Th. Rögnvaldsson and L. Lönnblad: JETNET 3.0 - A versatile artificial neural network package. *Comput. Phys. Commun.* 81(1994)185.
- [92] A. Hoecker, P. Speckmayer, J. Stelzer, J. Therhaag, E. von Toerne, H. Voss: *TMVA 4.2.0 – Toolkit for Multivariate Data Analysis*

- with ROOT*, arXiv:physics/0703039 [Data Analysis, Statistics and Probability] CERN-OPEN-2007-007, TMVA version 4.2.0, October 4, 2013; <http://tmva.sourceforge.net>
- [93] R. Brun and F. Rademakers, “ROOT - An Object Oriented Data Analysis Framework”, Nucl. Inst. Meth. in Phys. Res. A 389, 81 (1997).
- [94] Salim Lahmiri: *A Comparative Study of Backpropagation Algorithms in Financial Prediction*, International Journal of Computer Science, Engineering and Applications (IJCSEA) Vol.1, №4, August 2011, pp. 15-21.
- [95] Гилл Ф., Мюррей У., Райт М. Практическая оптимизация. Пер. с англ. — М.: Мир, 1985, - 972 с.
- [96] Максимов Ю. А., Филлиповская Е. А. Алгоритмы решения задач нелинейного программирования. — М.: МИФИ, 1982.
- [97] С.К. Chui: *An Introduction to Wavelets*. Academic Press: New York, 1-18(1992).
- [98] S. Mallat: *A Wavelet Tour of Signal Processing*, Academic Press, 1999.
- [99] W.H. Press, S.A. Teukolsky, W.T. Vetterling and B.P. Flannery: *Numerical Recipes in C: The Art of Scientific Computing*, II-d Edition, Cambridge University Press 1988, 1992.
- [100] I. Daubechies: *Wavelets*, Philadelphia: S.I.A.M., 1992.
- [101] I. Antoniou, V.V. Ivanov, Valery V. Ivanov and P.V. Zrellov: *Wavelet Filtering of Network Traffic Measurements*, JINR Communication, E11-2002-223, JINR, Dubna, RUSSIA, 2002, 21 pp.; Physica A 324 (2003) 733-753.
- [102] W.T. Eadie, D. Dryard, F.E. James, M. Roos and B. Sadoulet: *Statistical Methods in Experimental Physics*, North-Holland Pub.Comp., Amsterdam-London, 1971.
- [103] F. James and M. Roos: *MINUIT – Function Minimization and Error Analysis*, CERN Program Library D506, 1988.

- [104] R. Brun, O. Couet, C. Vandoni and P. Zanarini: *PAW - Physics Analysis Workstation*, CERN Program Library Q121, 1989.
- [105] Г.В. Мартынов: *Критерии омега-квадрат*, Москва, “Наука”, 1978.
- [106] D.S. Broomhead and G.P. King: *Time-series Analysis*, Proc. Roy. Soc. London, 423, 103-110 (1989).
- [107] D.S. Broomhead and G.P. King: *Extracting qualitative dynamics from experimental data*, Physica **20D** (1986), 217.
- [108] A.M. Albano, J. Muench, C. Schwartz, A.I. Mees, and P.E. Rapp: *Singular value decomposition and the Grassberger Procaccia algorithm*, Phys. Rev. **A38** (1988), 3017.
- [109] J.B. Elsner and A.A. Tsonis: *Singular Spectrum Analysis. A New Tool in Time Series Analysis*, Plenum Press, New York and London, 1996.
- [110] Д.Л. Данилов, А.А. Жиглявский (ред.): *Главные компоненты временных рядов: метод “Гусеница”*, Изд-во СПбГУ, 1997.
- [111] <http://www.gistatgroup.com/cat/> (дата обращения: 18.01.2016).
- [112] Nonparametric statistical inference by Jean Dickinson Gibbons, Subhabrata Chakraborti, 4th Edition, CRC Press, 2003, ISBN 978-0-8247-4052-8.
- [113] Testing for Normality, by Henry C. Thode, CRC Press, 2002, ISBN 978-0-8247-9613-6, Section 2.2.3, Percent–percent plots.
- [114] Shorack, G.R., Wellner, J.A (1986) Empirical Processes with Applications to Statistics, Wiley. ISBN 0-471-86725-X pp. 248–250.
- [115] C.G. Broyden, "The Convergence of a Class of Double-rank Minimization Algorithms J. Inst. of Math. and App. 6, 76 (1970); R. Fletcher, A New Approach to Variable Metric Algorithms Computer J. 13, 317 (1970); D. Goldfarb, "A Family of Variable Metric Updates Derived by Variational Means Math. Comp. 24, 23 (1970); D.F. Shannon, Conditioning of Quasi-Newton Methods for Function Minimization Math. Comp. 24, 647 (1970).

- [116] Камынин Л.И. Математический анализ. Т. 1, 2. - 2001.
- [117] Кудрявцев Л.Д «Краткий курс математического анализа. Т.2. Дифференциальное и интегральное исчисления функций многих переменных. Гармонический анализ», ФИЗМАТЛИТ, 2002, — 424 с. — ISBN 5-9221-0185-4.
- [118] Голубицкий М., Гийемин В. Устойчивые отображения и их особенности, — М.: Мир, 1977
- [119] Nocedal, George; Wright, Stephen J. Numerical Optimization. — 2nd edition. — USA: Springer, 2006
- [120] Avriel, Mordecai. Nonlinear Programming: Analysis and Methods. — Dover Publishing, 2003.
- [121] Osetrov E.: Mathematical Techniques and Approaches to Forecast Passengers' Demand for Transport Services to Provide Sustainable Development // Applied Mathematical Sciences, Vol. 9, 2015, № 108, p.5353 – 5359.
- [122] Осетров Е.С.: Анализ современных подходов прогнозирования спроса пассажиров на транспортные услуги // Экономический анализ: теория и практика, 2015 , № 47 (446), с.52-60.
- [123] Иванов В.В., Осетров Е.С.: Прогнозирование объемов пассажирских перевозок в Московском метрополитене с помощью искусственных нейронных сетей // Вестник Национального исследовательского ядерного университета “МИФИ” (Математическое и компьютерное моделирование), 2016, том 5, № 1, с. 65-74.
- [124] Иванов В.В., Осетров Е.С.: Прогнозирование пассажиропотока в Московском метрополитене на основе нейронных сетей с предварительной фильтрацией анализируемых данных (Математическое и компьютерное моделирование) // Вестник Национального исследовательского ядерного университета “МИФИ” (Математическое и компьютерное моделирование), 2016, том 5, № 2, с. 162-169.



- [125] Иванов В.В., Крянев А.В., Осетров Е.С.: Прогнозирование суточного потребления электроэнергии в московском регионе на основе сингулярно-спектрального анализа // Вестник Национального исследовательского ядерного университета “МИФИ” (Прикладная математика и информатика), 2017, том 6, № 2, с. 56–71
- [126] Иванов В.В., Крянев А.В., Осетров Е.С.: Прогнозирование суточного потребления электроэнергии в московском регионе на основе сингулярно-спектрального анализа // Материалы всероссийской конференции с международным участием Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем, «РУДН», 2017, с.283-285.
- [127] Иванов В.В., Крянев А.В., Осетров Е.С.: Прогнозирование суточного потребления электроэнергии в Московском регионе с использованием искусственных нейронных сетей // Письма в ЭЧАЯ, 2017, том 14, №4(209), с.418-432.
- [128] Ivanov V., Osetrov E.: Application of artificial neural networks and singular-spectral analysis in forecasting the daily passenger’s traffic in the Moscow metro // EPJ Web of Conferences 173, 05009 (2018) Mathematical Modeling and Computational Physics 2017, <https://doi.org/10.1051/epjconf/20181705009>.
- [129] Иванов В.В., Осетров Е.С.: Прогнозирование суточных объемов пассажирских перевозок в Московском метрополитене // Письма в ЭЧАЯ, том 15, выпуск 1, 2018, с.107-120.