

МОСКОВСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
имени М. В. ЛОМОНОСОВА  
ЭКОНОМИЧЕСКИЙ ФАКУЛЬТЕТ

*На правах рукописи*

**Джункеев Урмат Кубанович**

**Прогнозирование инфляции на основе методов машинного обучения**

Специальность 5.2.1. Экономическая теория

**ДИССЕРТАЦИЯ**

на соискание ученой степени  
кандидата экономических наук

Научный руководитель:  
доктор экономических наук, профессор,  
Вереникин Алексей Олегович

Москва – 2026

**Оглавление**

<b>Введение.....</b>	<b>3</b>
<b>Глава 1. Методологические подходы к прогнозированию инфляции .....</b>	<b>12</b>
1.1. Эконометрические методы прогнозирования инфляции .....	12
1.2. Прогнозирование динамики цен байесовскими методами.....	17
1.3. Применение ансамблевых методов для прогнозирования динамики цен .....	21
1.4. Прогнозирование инфляции на основе нейросетевых методов.....	26
1.5. Разработка моделей комбинирования для прогноза инфляции в России .....	34
<b>Глава 2. Теоретические подходы к анализу макроэкономических факторов инфляции .....</b>	<b>43</b>
2.1. Анализ динамики цен на основе показателей рынка труда .....	43
2.2. Механизмы влияния показателей производственного сектора на инфляцию .....	47
2.3. Взаимосвязь между инфляцией и показателями финансовой системы .....	53
2.4. Учет инфляционных ожиданий при изучении ценовой динамики .....	65
2.5. Формирование выборки для прогноза российской инфляции.....	74
<b>Глава 3. Использование ансамблевых и нейросетевых методов для прогнозирования инфляции в России .....</b>	<b>79</b>
3.1. Описание статистических данных для прогноза динамики цен в России .....	79
3.2. Алгоритм прогнозирования инфляции в России.....	85
3.3. Результаты прогнозирования российской инфляции .....	92
<b>Заключение.....</b>	<b>106</b>
<b>Список использованных источников.....</b>	<b>110</b>
<b>Приложения .....</b>	<b>125</b>

## Введение

**Актуальность темы исследования.** Прогнозирование динамики цен приобрело все большую актуальность с переходом Центрального банка Российской Федерации к режиму инфляционного таргетирования. Актуальность составления точных прогнозов инфляции обусловлена тем, что решения по денежно-кредитной политике основываются как на текущей информации о конъюнктуре экономики, так и на будущих сценариях развития макроэкономики. Помимо Центрального банка в точных прогнозах динамики цен заинтересованы частные фирмы и домашние хозяйства. Это объясняется тем, что доходы, долговые обязательства, трудовые контракты, сбережения и инвестиции формируются в номинальном выражении.

В международной академической среде отмечается, что методы машинного обучения могут предоставлять более точные прогнозы инфляции по сравнению с базовыми моделями, такими как авторегрессионные модели первого и более высокого порядка, кривые Филлипса, экспертные оценки, модели ненаблюдаемой компоненты со стохастической волатильностью, модели случайного блуждания. Аналогичные результаты подтверждаются в российских исследованиях. Составление более точных прогнозов инфляции методами машинного обучения по сравнению с базовыми моделями может объясняться возможностью учета структурных сдвигов в экономике, нелинейных взаимосвязей между динамикой цен и показателями производственного сектора, рынка труда, финансового сектора.

Следовательно, с учетом структурных сдвигов, наблюдавшихся в экономике России, в частности, перехода к режиму инфляционного таргетирования, корректировки механизма бюджетного правила и введения ограничений на движение капитала, становится целесообразной разработка модельного аппарата прогнозирования инфляции, который принимает во внимание нелинейные и меняющиеся во времени взаимосвязи между инфляцией и ключевыми макроэкономическими факторами ценовой стабильности. Помимо внутривосточных преобразований на протяжении исследуемого периода структурные сдвиги наблюдались в мировой экономике: пандемический кризис, рост цен на сырьевые товары, цикл ужесточения денежно-кредитной политики в развитых странах.

**Степень научной разработанности проблемы.** К числу зарубежных исследований в области прогнозирования инфляции, основанных на кривой Филлипса, относятся работы А. Аткенсона<sup>1</sup>, Ю. А. Городниченко, О. Койбиона, Л. Оганиана, Дж. Стока, М. Уотсона, Дж. Урайта, Дж. Фауста. Оценке кривой Филлипса в задаче выявления закономерностей развития российской инфляции уделяли внимание Б. Н. Гафаров, Е. Б. Дерюгина, О. А. Замулин, А. В. Зубарев, Ф. С. Картаев, Д. А. Мухин, Д. А. Орлов, А. А. Пономаренко, Е. А. Постников, А. В. Соколова, К. А. Стырин. К числу альтернативных методов оценки динамики российской инфляции, обладающих микроэкономическими обоснованиями, относятся динамические стохастические модели общего равновесия, разработанные М. Ю. Андреевым, Д. А. Крепцевым, А. В. Полбиным, С. М. Селезевым, А. Р. Шарафутдиновым. Оценке эконометрических моделей, исследующих закономерности ценовой стабильности в России, посвящены работы А. Андреева, А. В. Божечковой, С. М. Дробышевского, Ю. Н. Перевышина, П. В. Трунина, А. А. Синякова.

Помимо использования эконометрических моделей составление прогнозов инфляции может быть основано на ансамблевых методах машинного обучения, чему посвящены зарубежные работы Г. Арайо, В. Гаглианоне, А. Иноуэ, А. Йозефа, Л. Килиана, М. Медейроса, Ч. Чакраборти. Прогнозирование динамики цен в России с помощью ансамблевых моделей машинного обучения также рассматривается в научных исследованиях И. К. Байбузы, О. Н. Семитуркина, А. А. Шевелева, Е. С. Шуляк.

Нейросетевому подходу к прогнозированию инфляции посвящены зарубежные исследования А. Андресена, Ф. Коломбе, Н. Кэмерона, М. Марселино, С. Мошири, Э. Накамуры, О. Паранхос, Н. Хаузенбергера, Ф. Хубера. При прогнозировании российской инфляции нейросетевые модели также находят практическое применение в научных работах М. О. Мамедли, Е. Е. Павлова, Д. С. Шибитова.

Прогнозирование инфляции на основе байесовского усреднения моделей осуществляется в работах Г. Купа, Д. Коробилиса, К. Стырина, Т. Кларка, Дж. Митчелла, С. Поттера, Н. Хаузенбергера. Учету структурных сдвигов в байесовских моделях прогнозирования инфляции посвящены зарубежные исследования С. Гордона, Г. Купа, Дж. Маха, С. Поттера. Среди российских исследований, посвященных прогнозированию инфляции, стоит отметить работы Ю. Н. Перевышина, Д. В. Третьякова, Н. Д. Фокина, в

---

<sup>1</sup> Полные библиографические ссылки на работы всех авторов, упоминаемых в тексте, приведены в списке использованных источников.

которых предпринимаются попытки учета структурных сдвигов в экономической конъюнктуре. Разработанный подход предполагает внедрение ретроспективно заданных фиктивных переменных, отделяющих периоды до и после возникновения структурных сдвигов, к числу которых относится переход Банка России к режиму инфляционного таргетирования, разрыв логистических цепочек в поставках товаров. Однако подобный подход ограничивает возможности принятия во внимание структурных сдвигов, которые могут возникнуть в будущем. Объясняется это тем, что модели оценивались с учетом экспертно-заданных структурных сдвигов только за период, доступный на момент прогнозирования инфляции.

**Цель и задачи исследования.** Целью исследования является разработка модельного аппарата для прогнозирования инфляции в Российской Федерации.

Для достижения поставленной цели необходимо решить следующие задачи:

- 1) Предложить модификации методов машинного обучения, ориентированные на применение в прогнозировании инфляции в Российской Федерации. Привести теоретическое обоснование применимости нелинейных методов машинного обучения в прогнозировании инфляции.
- 2) Разработать модели, основанные на комбинировании прогнозов модифицированных ансамблевых и нейросетевых методов машинного обучения. Выявить преимущества моделей градиентного бустинга и нейронных сетей, а также их комбинаций по сравнению с эконометрическими моделями прогнозирования инфляции на российских данных. Привести теоретическое обоснование применимости комбинаций моделей для прогнозирования инфляции.
- 3) Систематизировать теоретические механизмы влияния ключевых макроэкономических факторов ценовой стабильности на инфляцию.
- 4) Разработать алгоритмы преобразования выборочной совокупности в многомерные и блочные матрицы для прогнозирования инфляции ансамблевыми и нейросетевыми методами машинного обучения.
- 5) Оценить влияние пересмотров информации о макроэкономических показателях на точность прогнозов инфляции в России ансамблевыми и нейросетевыми методами машинного обучения с использованием предварительных и пересмотренных статистических данных. Определить теоретическую взаимосвязь между пересмотрами статистической информации и проблемой эндогенности моделей вследствие ошибок измерения.

- б) На основе вектора Шепли привести содержательную интерпретацию наиболее точных прогнозов инфляции в Российской Федерации, полученных ансамблевыми и нейросетевыми методами машинного обучения.

**Объектом исследования** являются инфляционные процессы в Российской Федерации.

В качестве **предмета исследования** выступают механизмы влияния макроэкономических факторов на инфляцию в Российской Федерации.

### **Научная новизна.**

- 1) На основе анализа нелинейных взаимосвязей между уровнем цен и показателями экономической активности теоретически обоснована целесообразность использования модифицированных методов машинного обучения при выработке прогнозов инфляции в России: моделей управляемого рекуррентного блока и долгой краткосрочной памяти; адаптивного, поправочного, упорядоченного градиентного бустинга; сверточных и рекуррентных нейронных сетей. Доказано, что данные модификации способны преодолеть ряд ограничений, присущих методам машинного обучения, применяемым в исследованиях инфляционных процессов – учесть лаговую структуру макроэкономических показателей, что не позволяют сделать полносвязные нейронные сети, и снизить высокие издержки выявления локального минимума функции оптимизации, свойственные традиционным алгоритмам градиентного бустинга.

- 2) В развитие существующих теоретических подходов и их реализации в деятельности монетарных регуляторов, в частности, в практике Банка России, разработаны модели прогнозирования инфляции, основанные на комбинировании результатов ансамблевых и нейросетевых методов, которые учитывают нелинейные и меняющиеся во времени взаимосвязи между инфляцией и макроэкономическими факторами ценовой стабильности. С учетом среднеквадратических ошибок прогнозов, а также информационного критерия Акаики, теста Дибольда-Мариано и статистического теста на определение доверительного множества моделей выявлены преимущества предложенных моделей комбинирования перед эконометрическим инструментарием прогнозирования инфляции в России (авторегрессией первого порядка; байесовской векторной авторегрессией; кривой Филлипса).

- 3) Систематизированы трансмиссионные механизмы влияния макроэкономических показателей на инфляционные процессы. Предложенная систематизация позволила определить теоретически обоснованное множество макроэкономических факторов ценовой

стабильности, которое обеспечивает повышение точности прогнозирования инфляции в Российской Федерации и получение содержательной интерпретации оценок ансамблевых и нейросетевых методов машинного обучения.

4) Разработаны алгоритмы преобразования выборочной совокупности в многомерные и блочные матрицы, позволяющие составлять прогнозы инфляции с помощью предложенных модифицированных методов машинного обучения.

5) Разработан алгоритм, на основе которого оценивается влияние пересмотров статистических данных на изменение точности прогнозов моделей. Первым этапом является сохранение оптимальных параметров нейросетевых и ансамблевых методов машинного обучения, по которым получены наиболее точные прогнозы российской инфляции на предварительных данных. На втором этапе сравнивается точность прогноза инфляции в России, полученного на основе предварительной и пересмотренной статистической информации по макроэкономическим показателям. Реализация предложенного алгоритма позволила теоретически и эмпирически обосновать наличие взаимосвязи между пересмотрами статистической информации и проблемой эндогенности моделей прогнозирования инфляции.

6) На основе вектора Шепли определены макроэкономические показатели, характеризующие результативность денежно-кредитной и бюджетно-налоговой политики, состояние реального сектора экономики и социальной сферы, динамику цен и валютных курсов в мирохозяйственной системе, учет которых приводит к более точным прогнозам инфляции в Российской Федерации ансамблевыми и нейросетевыми методами машинного обучения. Проведенный анализ позволил уточнить механизмы влияния данных макроэкономических показателей на состояние народнохозяйственной системы.

**Теоретической значимостью** диссертации является развитие методологических подходов к прогнозированию инфляции. Предложенная методика принимает во внимание наличие нелинейной взаимосвязи между инфляцией и ключевыми макроэкономическими переменными производственного и финансового секторов. Методологическая значимость предложенного подхода к прогнозированию инфляции заключается также в учете возникновения структурных сдвигов, что обеспечивается за счет меняющихся во времени параметров, оцениваемых методами машинного обучения. Интерпретация прогнозов, полученных ансамблевыми и нейросетевыми методами машинного обучения, вектором Шепли позволяет проверить теоретические предпосылки о наличии взаимосвязи инфляции и макроэкономических показателей рынка труда, производственного сектора, финансовой системы.

Результаты диссертационной работы имеют **практическую значимость** для: 1) Банка России при изучении закономерностей развития инфляции и последующем проведении денежно-кредитной политики; 2) Министерства финансов Российской Федерации при оценке изменения ценовых показателей, учитываемых в процессе формирования бюджетно-налоговой политики; 3) Минэкономразвития Российской Федерации при построении сценариев развития экономической конъюнктуры, предполагающих различные варианты ценовой стабильности.

Материалы диссертации содержат практику применения современных методов машинного обучения в научных исследованиях по экономической тематике. Поэтому данная научная работа может использоваться в деятельности образовательных организаций при преподавании учебных дисциплин, связанных с прогнозированием микро- и макроэкономических показателей на основе методов машинного обучения.

**Теоретико-методологические основы исследования.** Теоретической основой исследования являются научные результаты, полученные при разработке новокейнсианских моделей и теории рациональных ожиданий. Методологической основой диссертации являются работы, посвященные прогнозированию инфляции на основе эконометрических моделей. Наряду с эконометрическими моделями для прогнозирования российской инфляции в диссертационной работе применялись такие методы машинного обучения как рекуррентные и сверточные нейронные сети, адаптивный, упорядоченный, поправочный градиентный бустинг, модели случайного леса, бэггинга, управляемого рекуррентного блока и долгой краткосрочной памяти, нейронные сети прямого распространения.

Для выявления фундаментальных факторов ценовой стабильности использовались общенаучные методы анализа и синтеза. Для систематизации эмпирических подходов к прогнозированию инфляции использовались методы группировки и сравнения.

**Информационная база исследования** сформирована на основе статистических данных Федеральной службы государственной статистики, Банка России, Министерства Финансов Российской Федерации. Наряду с источниками официальных государственных ведомств России используются статистические данные международных организаций, таких как Продовольственная и сельскохозяйственная организация, Резервный банк Сент-Луиса, Всемирный банк.

### **Положения, выносимые на защиту.**

1. Представленные в диссертации модификации методов машинного обучения, таких как: 1) адаптивный, 2) упорядоченный, 3) поправочный градиентный бустинг; 4) сверточные, 5) рекуррентные нейронные сети; 6) модель долгой краткосрочной памяти; 7) модель управляемого рекуррентного блока, являются альтернативой традиционных эконометрических подходов при прогнозировании инфляции в российской экономике.

2. Учет структурных сдвигов в экономической конъюнктуре, значимо влияющих на результаты моделирования, может быть осуществлен с помощью разработанных в диссертации четырех типовых моделей, которые основаны на комбинировании прогнозов, полученных различными методами машинного обучения. Первая модель строится на базе прогнозов, которые дают ансамблевые методы машинного обучения. Во второй модели комбинируются прогнозы моделей нейронных сетей. Третья модель представляет собой комбинацию прогнозных значений оцениваемого показателя, рассчитанных с использованием градиентного бустинга и нейронных сетей. Компоненты четвертой модели выбираются по результатам эконометрического теста на доверительное множество моделей. Сравнение точности прогнозов, полученных модифицированными методами машинного обучения, и расчетов, использующих аппарат кривой Филлипса, а также байесовской векторной авторегрессии, на основе информационного критерия Акаики и эконометрического теста на доверительное множество моделей демонстрирует преимущества методов машинного обучения перед эконометрическими моделями.

3. Представленный в диссертации комплексный трансмиссионный механизм влияния макроэкономических показателей на ценовую стабильность позволяет сформировать теоретически обоснованную выборку факторов для прогнозирования инфляции в российской экономике.

4. Для прогнозирования инфляции модифицированными методами машинного обучения требуются специальные алгоритмы подготовки многомерных матриц, разработанные и реализованные в рамках данной диссертационной работы. Первый алгоритм служит формированию блочной выборки, которая позволяет применять ансамблевые модели для многопериодного прогнозирования. Второй алгоритм направлен на создание трехмерной выборки, которая предоставляет возможности для прогнозирования инфляции моделями сверточных и рекуррентных нейронных сетей.

5. Прогнозирование макроэкономических показателей предполагает периодическое уточнение статистической информации официальных ведомств. Предложенные в диссертации модификации ансамблевых и нейросетевых методов машинного обучения

позволяют генерировать прогнозы инфляции как на предварительных, так и на пересмотренных статистических данных и преодолевать, тем самым, проблемы эндогенности моделей, возникающие из-за ошибок измерения.

6. Подход к интерпретации результатов прогнозирования инфляции моделями градиентного бустинга и случайного леса на основе атрибута важности переменных не является универсальным и не может применяться к результатам моделей нейронных сетей. Предложенный в диссертации подход на основе вычисления вектора Шепли позволяет интерпретировать результаты прогнозов инфляции на российских данных, полученных с использованием как ансамблевых, так и нейросетевых методов машинного обучения.

**Соответствие диссертации научной специальности.** Диссертация соответствует научной специальности 5.2.1. Экономическая теория. Направления исследований: 9. «Макроэкономическая теория», 18. «Междисциплинарные аспекты экономических исследований».

**Апробация результатов исследования.** Результаты исследования прошли апробацию на следующих конференциях:

- Ясинские чтения НИУ ВШЭ, 24 апреля 2024 г. Доклад на тему «Прогнозирование ВВП комбинациями ансамблевых и нейросетевых методов машинного обучения».
- XXIV Ясинская (Апрельская) международная научная конференция по проблемам развития экономики и общества, 13 апреля 2023 г. Доклад на тему «Прогнозирование инфляции в России на основе алгоритмов градиентного бустинга и нейронных сетей».
- XXIV Ясинская (Апрельская) международная научная конференция по проблемам развития экономики и общества, 13 апреля 2023 г. Доклад на тему «Анализ эффективности денежно-кредитной политики в странах-экспортерах сырья, таргетирующих инфляцию» совместно с А. В. Божечковой.
- XXIII Ясинская (Апрельская) международная научная конференция по проблемам развития экономики и общества, 5-22 апреля 2022 г. Доклад на тему «Информационная жесткость и возможности для денежно-кредитной политики: первые оценки для России» совместно с А. В. Божечковой, А. С. Евсеевым, М. Е. Чембулатовой.
- Ежегодная научная конференция «Ломоносовские чтения. Секция экономических наук», 20-23 апреля 2021 г. Доклад на тему «Применение методов машинного обучения в экономических исследованиях».

- Международный молодежный научный форум «Ломоносов-2021». Секция «Экономика», подсекция «Макроэкономика», 12-23 апреля 2021 г. Доклад на тему «Моделирование влияния кредитного сектора на динамику валового внутреннего продукта».

Основные выводы и результаты диссертационного исследования представлены в 5 публикациях автора. Все 5 статей (общий объем 6 п.л., в том числе авторских 5,3 п.л.) опубликованы в журналах из списка рецензируемых научных изданий, рекомендованных для защиты в диссертационном совете МГУ имени М.В. Ломоносова по специальности и отрасли наук; в том числе 5 статей в списке научных изданий, входящих в базу научного цитирования RSCI.

### **Структура диссертации.**

Поставленные цель и задачи работы определяют логику и структуру диссертации. Диссертация состоит из введения, трех глав, заключения, списка использованных источников и приложения. Общий объем диссертации – 134 страницы. Список использованных источников включает в себя 208 наименований.

## Глава 1. Методологические подходы к прогнозированию инфляции<sup>2</sup>

Данная глава посвящена описанию методов прогнозирования инфляции. В параграфе 1.1 приведены эконометрические модели. В параграфе 1.2 рассматриваются байесовские методы, преимущество которых заключается в учете меняющейся во времени взаимосвязи между инфляцией и факторами ценовой стабильности. В параграфе 1.3 изучаются ансамблевые методы, которые агрегируют прогнозы множества базовых моделей. Параграф 1.4 включает описание моделей нейронных сетей, преимущество которых состоит в возможности учета нелинейной взаимосвязи между динамикой цен и факторами ценовой стабильности. В параграфе 1.5 приведено описание авторских моделей, которые комбинируют прогнозы модифицированных ансамблевых и нейросетевых методов машинного обучения.

### 1.1. Эконометрические методы прогнозирования инфляции

В начале настоящего параграфа приведем общую спецификацию эконометрических моделей. Далее перечислим частные случаи общей спецификации эконометрических моделей. Затем приведем научные работы, которые посвящены применению эконометрических моделей для прогнозирования инфляции.

В настоящей диссертации рассматривается общая спецификация эконометрических моделей следующего вида (1.1.1):

$$y = X\beta + \varepsilon, \quad (1.1.1)$$

где  $y$  – объясняемая (зависимая) переменная, которая имеет размерность  $(T \times 1)$ ;

$X$  – объясняющие (независимые) переменные, которые составляют матрицу размерности  $(T \times n)$ ;

$n$  – количество объясняющих переменных, включая константу;  $T$  – количество периодов времени;

$\varepsilon$  – случайные ошибки, которые имеют распределение Гаусса  $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_T)$ ;

---

<sup>2</sup> При подготовке данной главы использованы материалы следующих публикаций автора: [Джункеев, 2022, 2024].

$\sigma^2$  – дисперсия случайных ошибок  $\varepsilon$ ;

$I_T$  – диагональная матрица размерности  $(T \times T)$ .

В предположении того, что существует обратная матрица  $(X^T X)^{-1}$ , прогнозы модели (1.1.1) имеют следующий вид:

$$\hat{y} = X\hat{\beta} = X(X^T X)^{-1}X^T y. \quad (1.1.2)$$

Далее мы приведем научные работы, в которых применяются следующие виды эконометрической модели (1.1.1) для прогнозирования инфляции: *авторегрессия; кривая Филлипса; модель ненаблюдаемой компоненты со стохастической волатильностью; модель случайного блуждания*. В Таблице 1.1.1 приведена подробная информация по научным работам, посвященным прогнозированию инфляции с помощью эконометрических моделей.

*Таблица 1.1.1 – Описание научных работ, посвященных прогнозированию инфляции на основе эконометрических моделей*

Исследование	Описание исследования
[Stock, Watson, 1999]	<b>Методология:</b> модели авторегрессии, случайного блуждания, кривой Филлипса с уровнем выпуска, безработицы, с разрывом выпуска, безработицы, который оценивается фильтром Ходрика-Прексотта. <b>Статистические данные:</b> с января 1970 г. по сентябрь 1996 г.; 1970-1983 гг., 1984-1996 гг. <b>Результаты:</b> модель кривой Филлипса с уровнем безработицы точнее прогнозирует инфляцию в США по сравнению с моделью авторегрессии, моделью случайного блуждания. Учет показателей выпуска по сравнению с показателями рынка труда повышает точность модели кривой Филлипса.
[Atkenson, Ohanian, 2001]	<b>Методология:</b> модели случайного блуждания, кривой Филлипса с разрывом безработицы, выпуска. <b>Статистические данные:</b> с января 1984 г. по ноябрь 1999 г. <b>Результаты:</b> по сравнению с моделью кривой Филлипса модель случайного блуждания точнее прогнозирует инфляцию в США.
[Stock, Watson 2007]	<b>Методология:</b> модель ненаблюдаемой компоненты со стохастической волатильностью (UCSV), авторегрессии, кривой Филлипса, случайного блуждания. <b>Статистические данные:</b> с I квартала 1984 г. по IV квартал 1983 г.; с I квартала 1984 г. по IV квартал 2004 г. <b>Результаты:</b> по сравнению с моделью авторегрессии первого порядка модели UCSV и кривой Филлипса точнее прогнозируют инфляцию в США
[Stock, Watson, 2008]	<b>Методология:</b> модель авторегрессии, случайного блуждания, UCSV, кривой Филлипса с уровнем безработицы и шоками предложения. <b>Статистические данные:</b> выборка за период с I квартала 1968 г. по IV квартал 2007 г. <b>Результаты:</b> по сравнению с моделью авторегрессии, кривой Филлипса модель UCSV точнее прогнозирует инфляцию в США

## Продолжение Таблицы 1.1.1

Исследование	Описание исследования
[Stock, Watson, 2010]	<p><b>Методология:</b> модель кривой Филлипса с трендовой инфляцией и разрывом безработицы, разрывом выпуска, UCSV, авторегрессии, случайного блуждания,</p> <p><b>Статистические данные:</b> с I квартала 1970 г. по I квартал 2010 г.</p> <p><b>Результаты:</b> по сравнению с моделью кривой Филлипса с разрывом безработицы, выпуска модель UCSV точнее прогнозирует инфляцию в США</p>
[Stella, Stock, 2013]	<p><b>Методология:</b> многомерная модель UCSV, модель случайного блуждания.</p> <p><b>Статистические данные:</b> с I квартала 1980 г. по IV квартал 1989 г.; с I квартала 1990 г. по IV квартал 1999 г.; с I квартала 2000 г. по III квартал 2011 г.</p> <p><b>Результаты:</b> по сравнению с моделью случайного блуждания многомерная модель UCSV точнее прогнозирует инфляцию в США</p>
[Андреев, 2016]	<p><b>Методология:</b> линейная регрессия, векторная авторегрессия, комбинирование авторегрессий и векторных авторегрессий.</p> <p><b>Статистические данные:</b> с января 2013 г. по декабрь 2015 г.</p> <p><b>Результаты:</b> метод комбинирования точнее прогнозирует инфляции в России по сравнению с моделью случайного блуждания, с ненаблюдаемой компонентой, векторной авторегрессией, байесовской векторной авторегрессией.</p>
[Третьяков, Фокин, 2021]	<p><b>Методология:</b> модели мостовых уравнений, со смешанной частотой данных (MIDAS), интегрированные авторегрессии со скользящим средним (ARIMA)</p> <p><b>Статистические данные:</b> с января 2010 г. по ноябрь 2019 г.</p> <p><b>Результаты:</b> по сравнению с ARIMA модели MIDAS точнее прогнозируют инфляцию в России. Учет структурного сдвига с января 2017 г. повышает точность моделей MIDAS.</p>
[Перевышин, 2022]	<p><b>Методология:</b> векторная модель коррекции ошибок</p> <p><b>Статистические данные:</b> с января 2010 г. по июнь 2022 г.</p> <p><b>Результаты:</b> по сравнению с моделью случайного блуждания, авторегрессии первого порядка, ARIMA векторная модель коррекции ошибок точнее прогнозирует инфляцию в России.</p>
[Banbura, Vobeica, 2023]	<p><b>Методология:</b> модель кривой Филлипса с уровнем, разрывом выпуска и безработицы, с ценами на нефть и сырьевые товары</p> <p><b>Статистические данные:</b> 2000-2018 гг.</p> <p><b>Результаты:</b> по сравнению с UCSV модель кривой Филлипса с меняющимися во времени параметрами (с трендовой инфляцией) точнее прогнозирует инфляцию в еврозоне.</p>
[Картаев, Беседовская, 2023]	<p><b>Методология:</b> модель авторегрессии 12-го порядка лага, прямые и треугольные модели кривой Филлипса (лаг инфляции, безработицы, промышленного производства, денежной массы, цен на нефть, индекса PMI), многомерные модели с валютным курсом, денежной массой, номинальной заработной платой.</p> <p><b>Статистические данные:</b> 2019-2022 гг.</p> <p><b>Результаты:</b> на горизонте 1 и 12 месяцев наиболее точные прогнозы инфляции предоставляет прямая модель кривой Филлипса.</p>

Источник: составлено автором.

Ниже перечислим ключевые виды эконометрических моделей, которые применяются для прогнозирования инфляции.

*Модель авторегрессии.* Уравнение (1.1.3) характеризует спецификацию авторегрессии первого порядка:

$$\pi_t = \rho\pi_{t-1} + \epsilon_t, \quad (1.1.3)$$

где  $\pi_t$  – фактическая инфляция;  $\epsilon_t$  – регрессионная ошибка.

В научных работах выявлено, что модель авторегрессии точнее прогнозирует инфляцию, чем кривые Филлипса [Stock, Watson, 1999; Картаев, Беседовская, 2023], факторные векторные авторегрессии, векторные авторегрессии с меняющимися во времени параметрами [Faust, Wright, 2013], байесовское усреднение моделей [Styrin, 2019], нейросетевые методы [Joseph, et al., 2022].

*Модель векторной авторегрессии.* Векторная авторегрессия представляется в форме системы (1.1.4):

$$Y_t = \sum_{i=1}^L \beta_i Y_{t-i} + \epsilon_t, \quad (1.1.4)$$

где  $Y_t$  – вектор, который содержит объясняемую и объясняющие переменные;

$i$  – порядок лага;  $\epsilon_t$  – случайные ошибки.

В исследованиях получено, что по сравнению с моделью случайного блуждания модель векторной авторегрессии [Андреев, 2016], векторная модель коррекции ошибок [Перевышин, 2022] точнее прогнозируют инфляцию. Модель смешанной частоты данных точнее прогнозирует инфляцию, чем интегрированная модель авторегрессии со скользящим средним [Третьяков, Фокин, 2021].

*Модель случайного блуждания.* Уравнение (1.1.5) характеризует спецификацию модели случайного блуждания (random walk, RW):

$$\pi_{t+h}^h = \frac{1}{h} \sum_{i=1}^h \pi_{t+i} + \epsilon_{t+h}, \quad (1.1.5)$$

где  $\pi_{t+h}^h$  – прогноз инфляции на  $h$ -горизонтов;

$\epsilon_t$  – регрессионная ошибка.

[Atkenson, Ohanian, 2001] выявили, что по сравнению с кривой Филлипса более точные прогнозы динамики цен предоставляет модель случайного блуждания.

*Модель ненаблюдаемой компоненты со стохастической волатильностью.* Система уравнений (1.1.6) характеризует спецификацию модели ненаблюдаемой компоненты со стохастической волатильностью:

$$\begin{cases} \pi_t = \tau_t + \eta_t, \eta_t = \sigma_{\eta,t} \zeta_{\eta,t} \\ \tau_t = \tau_t + \varepsilon_t, \varepsilon_t = \sigma_{\varepsilon,t} \zeta_{\varepsilon,t} \end{cases} \quad (1.1.6)$$

где  $\pi_t$  – фактическая инфляция;

$\tau_t$  – трендовая инфляция;

$\eta_t$  – циклическая инфляция;

$\sigma_{\eta,t}$  – среднее квадратическое отклонение  $\eta_t$ ;

$\varepsilon_t$  – случайная ошибка;

$\sigma_{\varepsilon,t}$  – среднее квадратическое отклонение  $\varepsilon_t$ ;  $\zeta_{\eta,t}, \zeta_{\varepsilon,t} \sim \mathcal{N}(0, I_2)$ .

В исследованиях получено, что по сравнению с моделями авторегрессии, случайного блуждания, кривой Филлипса модель ненаблюдаемой компоненты со стохастической волатильностью точнее прогнозирует инфляцию [Stock, Watson, 2008, 2010; Stella, Stock, 2013].

*Модель кривой Филлипса.* Кривая Филлипса характеризуется уравнением (1.1.7):

$$\pi_t = \alpha_1 \pi_{t-k} + \alpha_2 u_{t-k} + \alpha_3 z_{t-k} + \varepsilon_t, \quad (1.1.7)$$

где  $k$  – порядок лага;

$u_{t-k}$  – показатель предельных издержек;

$z_{t-k}$  – шоки предложения;

$\varepsilon_t$  – случайная ошибка.

Показателями предельных издержек  $u_t$  могут быть уровень безработицы, объем выпуска, разрыв выпуска как отклонение фактического объема выпуска от его потенциального уровня, разрыв безработицы, измеряемый отклонением фактического уровня безработицы от ее естественного уровня. Вместо лага инфляции  $\pi_{t-1}$  может использоваться ожидаемая инфляция  $\pi_{t+1}$ , что соответствует неокейнсианской модели кривой Филлипса. Шоками предложения могут быть цены на сырьевые товары.

В исследованиях получено, что модель кривой Филлипса прогнозирует инфляцию точнее, чем модели случайного блуждания [Stock, Watson, 1999], авторегрессии [Stock,

Watson, 2007; Картаев, Беседовская, 2023], ненаблюдаемой компоненты [Stock, Watson, 2008, 2010; Banbura, Bobeica, 2023].

В научных работах отмечается, что учет структурных сдвигов повышает точность прогноза эконометрических моделей: кривой Филлипса [Stock, Watson, 2010], смешанной частоты данных [Третьяков, Фокин, 2021], векторной коррекции ошибок [Перевышин, 2022]<sup>3</sup>. Следовательно, повышается актуальность применения тех статистических методов, которые позволяют учесть изменение параметров модели во времени из-за структурных сдвигов. К числу таких статистических методов относятся байесовские методы, описанию которых посвящен следующий параграф 1.2.

## 1.2. Прогнозирование динамики цен байесовскими методами

В параграфе 1.1 мы выяснили, что эконометрические модели позволяют точнее прогнозировать инфляцию по сравнению с эталонными моделями. В эконометрических моделях, которые оцениваются классической (частотной) статистикой, предполагается фиксированная взаимосвязь между переменными моделей. Однако в ряде исследований отвергается гипотеза о стабильности параметров модели кривой Филлипса [Stock, Watson, 2007, 2008; Гафаров, 2011]. В свою очередь, в моделях, которые оцениваются байесовской статистикой, предполагается, что параметры являются случайными величинами. Это предположение позволяет учесть структурные сдвиги.

В настоящем параграфе изучаются следующие виды байесовских методов для прогнозирования инфляции: *байесовские векторные авторегрессии; байесовское усреднение моделей*. В Таблице 1.2.1 приведена более подробная информация по научным работам, посвященным составлению прогнозов динамики цен с помощью байесовских методов.

---

<sup>3</sup> [Stock, Watson, 2010] отмечают, что к структурным сдвигам могут относиться переход от невозобновляемых к альтернативным источникам энергии, снижение доли участия работников в профсоюзах, шок цен на сырьевые товары. [Третьяков, Фокин, 2021] к числу структурных сдвигов относят переход к режиму инфляционного таргетирования, а [Перевышин, 2022] – рост стоимости доставок товаров из-за перебоев логистических цепочек.

Таблица 1.2.1 – Описание научных исследований, посвященных прогнозированию инфляции на основе байесовских методов

Исследование	Описание исследования
[Jacobson, Karlsson, 2004]	<p><b>Методология:</b> байесовское усреднение моделей</p> <p><b>Статистические данные:</b> с IV квартала 1997 г. по III квартал 2003 г.</p> <p><b>Результаты:</b> по сравнению с моделью случайного блуждания байесовское усреднение моделей точнее прогнозирует инфляцию в Швеции.</p>
[Koop, Potter, 2004]	<p><b>Методология:</b> байесовское усреднение моделей с методом главных компонент.</p> <p><b>Статистические данные:</b> с I квартала 1970 г. по IV квартал 2001 г.</p> <p><b>Результаты:</b> по сравнению с моделью авторегрессии первого порядка байесовское усреднение моделей точнее прогнозирует инфляцию в США.</p>
[Karpetanios, Labhard, Price, 2008]	<p><b>Методология:</b> байесовское усреднение моделей, информационно-теоретическое усреднение моделей</p> <p><b>Статистические данные:</b> со II квартала 1990 г. по I квартал 1997 г.; со II квартала 1997 г. по I квартал 2004 г.</p> <p><b>Результаты:</b> по сравнению с моделью авторегрессии, с информационно-теоретическим усреднением моделей байесовское усреднение моделей точнее прогнозирует инфляции в Великобритании на горизонте 5-6 месяцев.</p>
[Wright, 2009]	<p><b>Методология:</b> байесовское усреднение моделей, комбинирование прогнозов с равными весами для моделей, модель случайного блуждания</p> <p><b>Статистические данные:</b> с I квартала 1987 г. по I квартал 2006 г.</p> <p><b>Результаты:</b> по сравнению с комбинированием с равными весами для моделей, а также с моделью случайного блуждания байесовское усреднение моделей точнее прогнозирует инфляцию в США.</p>
[Koop, Korobilis, 2012]	<p><b>Методология:</b> динамическое усреднение моделей, динамический выбор моделей.</p> <p><b>Статистические данные:</b> со II квартала 1970 г. по IV квартал 2008 г.</p> <p><b>Результаты:</b> по сравнению с моделями ненаблюдаемой компоненты и случайного блуждания динамическое усреднение моделей точнее прогнозирует инфляцию в США.</p>
[Giannone et al., 2014]	<p><b>Методология:</b> байесовские векторные авторегрессии.</p> <p><b>Статистические данные:</b> со II квартала 2002 г. по I квартал 2012 г.</p> <p><b>Результаты:</b> по сравнению с моделью случайного блуждания модель байесовской векторной авторегрессии точнее прогнозирует инфляцию в еврозоне.</p>
[Giannone et al., 2015]	<p><b>Методология:</b> векторные авторегрессии, байесовские векторные авторегрессии.</p> <p><b>Статистические данные:</b> с IV квартала 1975 г. по IV квартал 2008 г.</p> <p><b>Результаты:</b> по сравнению с векторной авторегрессией модель байесовской векторной авторегрессии точнее прогнозирует дефлятор ВВП в США</p>

## Продолжение Таблицы 1.2.1

Исследование	Описание исследования
[Пестова, Мамонов, 2016]	<b>Методология:</b> байесовская векторная авторегрессия. <b>Статистические данные:</b> с января 2012 г. по сентябрь 2015 г. <b>Результаты:</b> по сравнению с моделями векторной авторегрессии и случайного блуждания байесовская векторная авторегрессия точнее прогнозирует инфляцию в России.
[Stygin, 2019]	<b>Методология:</b> динамическое усреднение моделей. <b>Статистические данные:</b> с марта 2007 г. по сентябрь 2017 г. <b>Результаты:</b> динамическое усреднение моделей не превосходит модель авторегрессии второго порядка по точности прогноза инфляции в России.

Источник: составлено автором.

Ниже перечислим ключевые характеристики байесовских методов для прогнозирования инфляции.

*Байесовские векторные авторегрессии (BVAR).* В параграфе 1.1 было отмечено, что модель векторной коррекции ошибок точнее прогнозирует инфляцию, чем модель авторегрессии и случайного блуждания [Перевышин, 2022]. Однако недостатком векторных авторегрессий является то, что в них учитывается небольшое количество переменных. Это может привести к проблеме пропуска существенных переменных. Вторым недостатком векторных авторегрессий является то, что они подвержены проблеме проклятия размерности: возникают трудности оценивания векторных авторегрессий, если количество переменных и их лагов превышает число наблюдений. Проблему пропуска существенных переменных и проклятия размерности могут решить байесовские векторные авторегрессии (1.2.1) через параметр сжатия пространства коэффициентов моделей:

$$\begin{cases} Y_t = X_t B + \varepsilon_t \\ p(B, \Sigma | Y_t) = \frac{p(Y_t | B, \Sigma) p(B, \Sigma)}{p(Y_t)} \end{cases} \quad (1.2.1)$$

где  $Y_t$  – множество эндогенных переменных;

$X_t$  – множество, которое включает константу, эндогенные переменные и их лаги;

$B$  – вектор параметров;

$\varepsilon_t$  – случайные ошибки;

$p(B, \Sigma | Y_t)$  – апостериорная плотность распределения параметров  $B$  и ковариационной матрицы случайных ошибок  $\Sigma$ ;

$p(Y_t)$  – функция правдоподобия;

$p(B, \Sigma)$  – априорная плотность распределения параметров  $B$  и ковариационной матрицы случайных ошибок  $\Sigma$ ;

$p(Y_t|B, \Sigma)$  – условная функция распределения эндогенных переменных.

В научной литературе получено, что байесовские векторные авторегрессии точнее прогнозируют инфляцию, чем модель случайного блуждания [Giannone et al., 2014], векторная авторегрессия [Giannone et al., 2015] и авторегрессия первого порядка [Пестова, Мамонов, 2016].

*Байесовское усреднение моделей (BMA)*. Уравнение (1.2.2) характеризует прогнозы, которые получены байесовским усреднением моделей:

$$\pi_{t,t+h} = \sum_{i=1}^n P(M_i|D) (\tilde{\alpha}_{i,t} + \tilde{\rho}_{i,t}\pi_{t-h,t} + \tilde{\gamma}_{i,t}z_t), \quad (1.2.2)$$

где  $P(M_i|D) = \frac{P(D|M_i)P(M_i)}{\sum_{j=1}^n P_j(D|M_j)P(M_j)}$  – апостериорная вероятность того, что  $i$ -ая модель

$(M_i)$  идентифицирует статистические закономерности;

$P(M_i)$  – априорная вероятность того, что  $i$ -ая модель идентифицирует статистические закономерности (процесс генерации данных);

$D$  – выборочная совокупность;

$P(D|M_i) = \int P(D|\theta_i, M_i)P(M_i|\theta_i)d\theta_i$  – функция правдоподобия;

$\theta_i$  – вектор параметров модели  $i$ ;  $P(M_i|\theta_i)$  – функция плотности для вектора параметров модели  $i$ ;

$\pi_{t-h,t}$  – лаг инфляции;  $z_t$  – факторы инфляции;

$\tilde{\alpha}_{i,t}, \tilde{\rho}_{i,t}, \tilde{\gamma}_{i,t}$  – апостериорные средние значения коэффициентов модели  $i$ . Если вектор коэффициентов линейной модели  $i$  равен  $\hat{\beta}_i = (X_i^T X_i)^{-1} X_i^T y$ , тогда вектор апостериорных средних значений коэффициентов модели  $i$  составляет  $\tilde{\beta}_i = \frac{\hat{\beta}_i \phi}{1+\phi} + \frac{\bar{\beta}}{1+\phi}$ , где  $\bar{\beta}$  – среднее значение вектора коэффициентов всех моделей;  $\phi$  – параметр сжатия. Если  $\phi = 0$ , тогда в комбинации устанавливаются равные веса для моделей. С ростом параметрам  $\phi$ , веса устанавливаются только для нескольких моделей согласно наблюдениям, нежели априорным значениям.

В академической литературе получено, что байесовское усреднение моделей точнее прогнозирует инфляцию, чем модель случайного блуждания [Jacobson, Karlsson, 2004],

среднее арифметическое прогнозов [Wright, 2009] и авторегрессия первого-второго порядка [Koop, Potter, 2004; Karpetanios, Labhard, Price, 2008].

[Koop, Korobilis, 2012] отмечают, что во времени могут меняться не только коэффициенты при переменных в модели, но также и набор переменных, который повышает точность модели. В связи с этой предпосылкой авторы предлагают прогнозировать инфляцию динамическим усреднением моделей (1.2.3):

$$\begin{cases} y_t = z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \\ \theta_{t+1}^{(k)} = z_t^{(k)} \theta_t^{(k)} + \eta_t^{(k)}, \end{cases} \quad (1.2.3)$$

где  $y_t$  – объясняемая переменная;

$z_t^{(k)}$  – модель  $k$  из множества  $K$  моделей;

$\theta_t^{(k)}$  – вектор параметров модели  $k$ ;

$\varepsilon_t^{(k)}, \eta_t^{(k)}$  – случайные ошибки, которые имеют стандартное нормальное распределение Гаусса  $\mathcal{N}(0,1)$ .

В научной литературе получено, что по точности прогноза инфляции динамическое усреднение моделей может как превзойти [Koop, Korobilis, 2012], так и не превзойти [Styrin, 2019] эталонные модели авторегрессии второго порядка, ненаблюдаемой компоненты, случайного блуждания, авторегрессии с меняющимися во времени параметрами.

Байесовский подход обладает существенными достоинствами применительно к комбинированию моделей. Так, байесовское усреднение моделей повышает точность прогноза инфляции. Подобная стратегия усреднения прогнозов также применяется при обучении ансамблевых методов машинного обучения, описанию которых посвящен следующий параграф 1.3.

### 1.3. Применение ансамблевых методов для прогнозирования динамики цен

В параграфе 1.2 мы выяснили, что комбинирование байесовских моделей точнее прогнозирует инфляцию, чем эталонные модели. Комбинирование также применяется для обучения ансамблевых методов машинного обучения. В начале настоящего параграфа приведем общую спецификацию ансамблевых методов. Далее изучим частные виды

ансамблевых методов. Затем приведем исследования, которые посвящены применению ансамблевых методов для прогнозирования инфляции.

Система (1.3.1) характеризует прогнозы, которые получены ансамблевыми методами:

$$\left\{ \begin{array}{l} f(x) = \frac{1}{N} \sum_{i=1}^N \hat{p}_i^{\text{базовая регрессия}} \hat{y}_i^{\text{базовая регрессия}} \\ \left\{ \hat{p}_i^{\text{базовая регрессия}} \right\}_{i=1}^N = \arg \min_{\left\{ p_i^{\text{базовая регрессия}} \right\}_{i=1}^N} \sum_{i=1}^N \left( y_i - p_i^{\text{базовая регрессия}} \hat{y}_i^{\text{базовая регрессия}} \right)^2, \end{array} \right. (1.3.1)$$

где  $f(x)$  – итоговый прогноз;

$\hat{p}_i^{\text{базовая регрессия}}$  – вес базовой регрессии  $i$  в ансамблевой модели;

$\hat{y}_i^{\text{базовая регрессия}}$  – прогноз базовой регрессии  $i$ ;

$x$  – вектор объясняющих переменных.

Прогноз на основе ансамблевых методов формируется в два этапа. На первом шаге минимизируется квадрат отклонения объясняемой переменной  $y_i$  от прогноза, который получен с помощью базовой регрессии (base learner)  $i$ . Решение задачи минимизации позволяет получить веса базовых регрессий. На втором шаге итоговый результат вычисляется как средневзвешенное значение прогнозов базовых регрессий [Athey, Imbens, 2019].

В настоящем параграфе изучаются следующие виды ансамблевых методов для прогнозирования инфляции: *случайный лес*; *градиентный бустинг*. В Таблице 1.3.1 приведена более подробная информация по научным работам, в которых применяются ансамблевые методы для прогнозирования инфляции.

Таблица 1.3.1 – Описание научных исследований, в которых применяются ансамблевые методы для прогнозирования инфляции

Исследование	Описание исследования
[Inoue, Kilian, 2008]	<b>Методология:</b> модель бэггинга. <b>Статистические данные:</b> с августа 1983 г. по июль 2007 г. <b>Результаты:</b> по сравнению с байесовским усреднением моделей, моделями LASSO, Ridge модель бэггинга точнее прогнозирует инфляцию в США.
[Garcia et al., 2017]	<b>Методология:</b> модели случайного леса <b>Статистические данные:</b> с января 2003 г. по декабрь 2015 г. <b>Результаты:</b> модели случайного леса точнее прогнозируют инфляцию в Бразилии по сравнению с моделями случайного блуждания и авторегрессии.

## Продолжение Таблицы 1.3.1

Исследование	Описание исследования
[Zeng, 2017]	<b>Методология:</b> модели градиентного бустинга. <b>Статистические данные:</b> с I квартала 2003 г. по IV квартал 2014 г. <b>Результаты:</b> по сравнению с авторегрессией модели градиентного бустинга точнее прогнозируют инфляцию в еврозоне.
[Baybuza, 2018]	<b>Методология:</b> модели случайного леса и градиентного бустинга. <b>Статистические данные:</b> с февраля 2005 г. по июнь 2016 г. <b>Результаты:</b> модель градиентного бустинга точнее прогнозирует инфляцию в России по сравнению с авторегрессией первого порядка.
[Medeiros et al., 2019]	<b>Методология:</b> модели градиентного бустинга и случайного леса. <b>Статистические данные:</b> с января 2001 г. по декабрь 2015 г. <b>Результаты:</b> модели случайного леса точнее прогнозируют инфляцию в США по сравнению с моделями ненаблюдаемой компоненты, случайного блуждания, байесовской векторной авторегрессии, Elastic Net, LASSO.
[Kohlscheen, 2022]	<b>Методология:</b> модели случайного леса. <b>Статистические данные:</b> с I квартала 2000 г. по II квартал 2021 г. <b>Результаты:</b> по сравнению с авторегрессией первого порядка модели случайного леса точнее прогнозируют инфляцию в 20 развитых странах.
[Semiturkin, Shevelev, 2023]	<b>Методология:</b> модели случайного леса и градиентного бустинга. <b>Статистические данные:</b> с февраля 2002 г. по декабрь 2020 г. <b>Результаты:</b> по сравнению с моделью ARIMA модели случайного леса и градиентного бустинга точнее прогнозируют инфляцию макрорегиона Сибирь.

Источник: составлено автором.

Ниже перечислим ключевые характеристики ансамблевых моделей для прогнозирования инфляции.

*Модель случайного леса.* Система (1.3.2) определяет прогнозы, которые получены моделью случайного леса [Hastie et al., 2009]:

$$\left\{ \begin{array}{l} f(x) = \sum_{m=1}^M \hat{c}_m I(x \in R_m), \hat{c}_m = \frac{1}{N_m} \sum_{x_i \in R_m} y_i, m = 1, 2, \dots, M \\ R_1(j, s) = \{X|X_j \leq s\}, R_2(j, s) = \{X|X_j > s\} \\ (j, s) \text{ выбираются исходя из } \min_{j,s} \left[ \min_{\hat{c}_1} \sum_{x_i \in R_1(j,s)} (y_i - \hat{c}_1)^2 + \min_{\hat{c}_2} \sum_{x_i \in R_2(j,s)} (y_i - \hat{c}_2)^2 \right], (1.3.2) \\ \hat{c}_1 = \frac{1}{N_1} \sum_{x_i \in R_1} y_i, \hat{c}_2 = \frac{1}{N_2} \sum_{x_i \in R_2} y_i \end{array} \right.$$

где  $y$  – объясняемая переменная;

$x$  – множество объясняющих переменных;

$R_m$  – подмножество наблюдений;

$N_m$  – количество наблюдений, которые относятся к подмножеству  $R_m$ ;

$X$  – вектор объясняющих переменных, с помощью которого составляются подмножества  $R_m$ ;

$X_j$  – объясняющая переменная  $j$ ;

$s$  – критерий, на основе которого составляются подмножества;

$I(\cdot)$  – индикаторная функция.

Прогноз по моделям случайного леса получается в три этапа. На первом этапе выборочная совокупность разделяется на  $M$  подмножеств. На втором этапе внутри подмножества  $m, m \in \{1, 2, \dots, M\}$  прогнозируется объясняемая переменная  $y$  базовой регрессией. На третьем этапе итоговым результатом является среднее значение прогнозов базовых регрессий каждого подмножества  $m$ .

*Модель градиентного бустинга.* Система (1.3.3) определяет прогнозы, которые получены моделью градиентного бустинга [Hastie et al., 2009]:

$$\begin{cases} f_m(x) = f_{m-1}(x) + \beta_m b(x; \gamma_m), f_0(x) = 0, m = 1, 2, \dots, M \\ (\beta_m, \gamma_m) = \underset{\beta, \gamma}{\operatorname{argmin}} \sum_{i=1}^N L(y_i, f_{m-1}(x_i) + \beta b(x_i; \gamma)) \end{cases}, \quad (1.3.3)$$

где  $b(x; \gamma_m)$  – ошибка прогноза базовой регрессии  $m$ ;

$\gamma_m$  – вектор параметров базовой регрессии  $m$ ;

$L(y_i, \cdot)$  – функция минимизации;

$x$  – множество объясняющих переменных;

$y_i$  – наблюдение  $i$  объясняемой переменной;

$\beta_m$  – коэффициент корректировки модели  $m$ .

Прогноз по моделям градиентного бустинга получается в три этапа. На первом этапе для базовой регрессии устанавливается нулевой прогноз. На втором этапе вычисляется квадрат отклонения объясняемой переменной от нулевого прогноза, и сохраняется ошибка прогноза базовой регрессии. На третьем этапе корректируется оценка базовой регрессии с учетом ошибок прогноза второго шага. Цикл повторяется  $M$  раз. Итоговым результатом является прогноз базовой регрессии, который получен на последней итерации  $M$ .

В научных исследованиях получено, что модели случайного леса и градиентного бустинга точнее прогнозируют инфляцию, чем модели авторегрессии [Zeng, 2017; Baybuza, 2018; Shulyak, 2022; Kohlscheen, 2022], байесовской векторной авторегрессии [Medeiros et

al., 2019], кривой Филлипса [Araujo, Gaglianone, 2023], случайного блуждания [Garcia et al., 2017; Medeiros et al., 2023], ARIMA [Semiturkin, Shevelev, 2023].

Стоит отметить, что среди перечисленных исследований недостаточно внимания уделяется модифицированным моделям градиентного бустинга, описание которых приводится ниже.

*Адаптивный бустинг AdaBoost* [Freund, Schapire, 1997]. С учетом выборочной совокупности  $\{(x_i, y_i)\}_{i=1}^N$  устанавливается вектор весов  $w_i^t$ . Вектор весов  $w^t$  необходим для вычисления ошибки моделей:

$$\epsilon_t = \sum_{i=1}^N w^t / \sum_{i=1}^N w_i^t |h_t(x_i) - y_i| \in [0,1],$$

где  $h_t(x_i): X \rightarrow [0,1]$  – базовая модель.

Механизм адаптации состоит в обновлении весов:

$$w_i^{t+1} = w_i^t \beta_t^{1-|h_t(x_i)-y_i|},$$

где  $\beta_t = \epsilon_t / (1 - \epsilon_t)$ .

Финальный результат составляет:

$$h_f(x) = \begin{cases} 1, & \text{если } \sum_{t=1}^T \left( \log \left( \frac{1}{\beta_t} \right) h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \log \left( \frac{1}{\beta_t} \right) \right) \\ 0, & \text{иначе} \end{cases}. \quad (1.3.4)$$

*Градиентный бустинг LightGBM* [Ke et al., 2017]. В модели градиентного бустинга LightGBM размер деревьев увеличивается на уровне листьев, но не на уровне переменных<sup>4</sup>. Для оценки значимости  $j$ -го показателя применяется прирост дисперсии (variance gain):

$$V_{j|O}(d) = \frac{1}{n_O} \left( \frac{\left( \sum_{\{x_i \in O: x_{ij} \leq d\}} g_i \right)^2}{n_{l|O}^j} + \frac{\left( \sum_{\{x_i \in O: x_{ij} > d\}} g_i \right)^2}{n_{r|O}^j} \right), \quad (1.3.5)$$

где  $d$  – значение порога, на основе которого выборочная совокупность разделяется на правый и левый узлы;

$g_i$  – антиградиент функции потерь по параметрам  $i$ -й модели;

$n_O = \sum I[x_i \in O]$  – количество наблюдений тренировочного множества;

$n_{l|O}^j(d) = \sum I[x_i \in O: x_{ij} \leq d]$  – наблюдения левого узла;

<sup>4</sup> Sklearn Min Max Scaler / Scikit-Learn: site. URL: <https://lightgbm.readthedocs.io/en/latest/Features.html> (дата обращения: 06.02.2024)

$n_{r|O}^j(d) = \sum I[x_i \in O: x_{ij} > d]$  – наблюдения правого узла.

Новизна LightGBM состоит в модифицированном приросте дисперсии:

$$\tilde{V}_j(d) = \frac{1}{n} \left( \frac{(\sum_{\{x_i \in A_l\}} g_i + \frac{1-a}{b} \sum_{\{x_i \in B_l\}} g_i)^2}{n_l^j(d)} + \frac{(\sum_{\{x_i \in A_r\}} g_i + \frac{1-a}{b} \sum_{\{x_i \in B_r\}} g_i)^2}{n_r^j(d)} \right), \quad (1.3.6)$$

где  $B_r = \{x_i \in B: x_{ij} > d\}$  и  $A_r = \{x_i \in A: x_{ij} > d\}$  – множества правого узла;

$B_l = \{x_i \in B: x_{ij} \leq d\}$  и  $A_l = \{x_i \in A: x_{ij} \leq d\}$  – множества левого узла.

*Градиентный бустинг CatBoost (Categorical Boosting)* [Dorogush et al., 2018; Prokhorenkova et al., 2018]. Модификация алгоритма CatBoost заключается в следующем: на случайно перемешанной (random permutation) выборке  $\sigma_r$  из множества комбинаций  $\{\sigma_1, \sigma_2, \dots, \sigma_s\}$  на каждой  $t$ -й итерации обучается дерево решений  $T_t$ . Прогнозы вспомогательной модели (supporting model)  $M_{r,j}(i)$  для следующего  $i$ -го наблюдения формируются на основе предыдущих  $j$ -х величин выборки  $\sigma_r$ .

Одним из пунктов новизны настоящей диссертации является применение модифицированных моделей градиентного бустинга для прогнозирования инфляции в России. Ансамблевые методы машинного обучения имеют ряд преимуществ по сравнению с базовыми моделями: решают проблему переобучения через агрегирование прогнозов множества моделей (например, деревьев решений), учитывают нелинейные взаимосвязи между переменными с помощью комбинации кусочно-линейных функций, идентифицируют наиболее значимые предикторы через бутстрап-выборки. Наряду с ансамблевыми методами машинного обучения точные прогнозы макроэкономических показателей могут быть получены с помощью нейронные сети [Ahmed et al., 2010]. В следующем параграфе 1.4 мы изучим нейросетевые методы, применяемые для прогнозирования инфляции.

#### 1.4. Прогнозирование инфляции на основе нейросетевых методов

В параграфе 1.3 мы выяснили, что ансамблевые методы по сравнению с эталонными моделями точнее прогнозируют инфляцию. Объясняется это тем, что ансамблевые модели учитывают нелинейную взаимосвязь между инфляцией и ее факторами. Нейросетевые методы также могут учесть нелинейную взаимосвязь между инфляцией и ее факторами.

Обеспечивается это нелинейными функциями активации, которые используются для получения результатов нейронной сети во входном, скрытых и выходном слоях. Помимо функций активации многослойная архитектура нейронных сетей позволяет выявлять нелинейные закономерности в статистических данных, в частности, в изображениях, имеющих многоуровневую структуру [Fan et al., 2021] (это может быть, например, информация о цветах, оттенках, тенях, форме объектов). [LeCun et al., 2015] отмечают, что первый скрытый слой нейронной сети идентифицирует контур объектов. Вторым скрытым слоем объединяет информацию о краях объектов. Последующие скрытые слои классифицируют объекты через комбинирование информации предыдущих слоев.

Общий вид нейронных сетей можно представить в виде системы (1.4.1):

$$\left\{ \begin{array}{l} h^{(L)} = g^{(L)} \circ g^{(L-1)} \circ \dots \circ g^{(1)}(x) \\ h^{(l)} = g^{(l)}(h^{(l-1)}) \triangleq \sigma(W^{(l)}h^{(l-1)} + b^{(l)}) \\ z = W^{(L+1)}h^{(L)} + b^{(L+1)} \\ f(x_i; \theta) \triangleq \frac{e^{z_k}}{\sum_k e^{z_k}} \\ l_{\mathcal{B}}(\theta) \triangleq \frac{1}{\mathcal{B}} \sum_{i \in \mathcal{B}} \mathcal{L}(f(x_i; \theta), y_i) \\ W^{(l)} = W^{(l)} - \frac{\partial l_{\mathcal{B}}}{\partial W^{(l)}} \end{array} \right. , \quad (1.4.1)$$

где  $h^{(l)}$  – результат слоя  $l \in \{0, 1, \dots, L\}$ ;

$\circ$  – оператор композиции функций;  $\triangleq$  – оператор присваивания;

$h^{(0)} \triangleq x$  – множество объясняющих переменных;

$g^{(l)}$  – функция активации. Например,  $\sigma(z) = \frac{1}{1+e^{-z}}$  – логистическая сигмоида;

$W^{(l)}$  – матрица весов слоя  $l$ ;  $b^{(l)}$  – вектор констант слоя  $l$ ;

$z$  – прогноз нейронной сети;  $y_i$  – наблюдение  $i$  целевой переменной;

$\mathcal{L}(f(x_i; \theta), y_i)$  – функция минимизации;  $\mathcal{B}$  – количество наблюдений.

Первое уравнение системы (1.4.1) означает, что нейронная сеть является композицией (суперпозицией)  $L$  функций активации. Согласно второму уравнению (1.4.1) результатом каждого слоя  $l$  является аффинное преобразование множества объясняющих переменных  $x$ . Прогноз нейронной сети формируется на выходном слое  $L + 1$ , что представлено в третьем уравнении системы (1.4.1). Прогнозы выходного слоя нормируются и используются для того, чтобы определить функцию минимизации  $\mathcal{L}(f(x_i; \theta), y_i)$ .

Градиент усредненной функции минимизации  $\frac{\partial l_B}{\partial W^{(l)}}$  применяется для обновления матрицы весов  $W^{(l)}$  [Fan et al., 2021].

В настоящем параграфе рассматриваются различные виды нейросетевых методов, используемых для прогнозирования инфляции, в том числе: *полносвязные (ANN)*, *сверточные (CNN)*, *рекуррентные (RNN)*, а также *модель долгой краткосрочной памяти (LSTM)* и *управляемый рекуррентный блок (GRU)*. В Таблице 1.4.1 приведена более подробная информация по научным работам, в которых применяются нейронные сети для прогнозирования инфляции.

Таблица 1.4.1 – Описание научных исследований, посвященные прогнозированию инфляции на основе нейронных сетей

Исследование	Методология и результаты исследования
[Moshiri, Cameron, 2000]	<b>Методология:</b> полносвязные нейронные сети, модель векторной авторегрессии <b>Статистические данные:</b> с января 1991 г. по декабрь 1994 г. <b>Результаты:</b> по сравнению с моделью ARIMA и векторной авторегрессией полносвязные нейронные сети точнее прогнозируют инфляцию в Канаде.
[Nakamura, 2005]	<b>Методология:</b> полносвязная нейронная сеть. <b>Статистические данные:</b> III квартал 1973 г. – I квартал 2003 г. <b>Результаты:</b> по сравнению с моделью авторегрессии первого-восьмого порядков полносвязная нейронная сеть точнее прогнозирует инфляцию в США.
[Chakraborty, Joseph, 2017]	<b>Методология:</b> методы $k$ -ближайших соседей и опорных векторов, модели случайного леса, комбинация прогнозов нейронной сети и метода опорных векторов. <b>Статистические данные:</b> I квартал 1990 г. – IV квартал 2015 г. <b>Результаты:</b> комбинация нейронной сети и метода опорных векторов точнее прогнозирует инфляцию в Великобритании по сравнению с моделями векторной авторегрессии.
[Aanes, Gulllien, 2018]	<b>Методология:</b> полносвязные и сверточные нейронные сети. <b>Статистические данные:</b> с января 1975 г. по декабрь 2017 г. <b>Результаты:</b> по сравнению с моделью случайного блуждания сверточные нейронные сети точнее прогнозируют инфляцию в Норвегии.
[Szafranek, 2019]	<b>Методология:</b> полносвязная нейронная сеть. <b>Статистические данные:</b> с января 1999 г. по декабрь 2016 г. <b>Результаты:</b> по сравнению с моделью ненаблюдаемой компоненты полносвязные нейронные сети точнее прогнозируют инфляцию в Польше.
[Pavlov, 2020]	<b>Методология:</b> полносвязная нейронная сеть, метод опорных векторов, модель Ridge, авторегрессия первого порядка. <b>Статистические данные:</b> с января 2002 г. по август 2018 г. <b>Результаты:</b> по сравнению с моделью авторегрессии первого порядка нейронные сети точнее прогнозируют инфляцию в России.

## Продолжение Таблицы 1.4.1

Исследование	Методология и результаты исследования
[Joseph et al., 2022]	<b>Методология:</b> метод опорных векторов, модели Ridge, LASSO, Elastic Net, случайного леса, полносвязные нейронные сети. <b>Статистические данные:</b> с января 2002 г. по ноябрь 2021 г. <b>Результаты:</b> по сравнению с моделями случайного леса и полносвязной нейронной сети модель авторегрессии второго порядка точнее прогнозирует инфляцию в Великобритании.
[Paranhos, 2021]	<b>Методология:</b> модель долгой краткосрочной памяти и полносвязная нейронная сеть. <b>Статистические данные:</b> с января 1959 г. по октябрь 2019 г. <b>Результаты:</b> по сравнению с полносвязными нейронными сетями модель долгой краткосрочной памяти точнее прогнозирует инфляцию в США.
[Hauzenberger et al., 2022]	<b>Методология:</b> байесовская нейронная сеть <b>Статистические данные:</b> с I квартала 1990 г. по IV квартал 2020 г. <b>Результаты:</b> по сравнению с линейной регрессией байесовская нейронная сеть точнее прогнозирует инфляцию в США в периоды рецессий.
[Hauzenberger et al., 2023]	<b>Методология:</b> модель долгой краткосрочной памяти <b>Статистические данные:</b> с января 1960 г. по январь 2021 г. <b>Результаты:</b> по сравнению с динамическими факторными моделями и авторегрессией второго порядка модель долгой краткосрочной памяти точнее прогнозирует инфляцию в США.
[Longo, Soltaneih-Ha, 2-23]	<b>Методология:</b> модель долгой краткосрочной памяти. <b>Статистические данные:</b> с I квартала 2008 г. по II квартал 2022 г. <b>Результаты:</b> по сравнению с кривой Филлипса модель долгой краткосрочной памяти точнее прогнозирует инфляцию в США

Источник: составлено автором.

Полносвязные нейронные сети (*Artificial Neural Networks, ANN*). Система (1.4.2) характеризует прогнозы, которые получены полносвязными нейронными сетями:

$$\begin{cases} f_k(X) = g_k(T), k = 1, 2, \dots, K \\ T_k = \beta_{0k} + \beta_k^T Z, k = 1, 2, \dots, K \\ Z_m = \sigma(\alpha_{0m} + \alpha_m^T X), m = 1, 2, \dots, M \end{cases}, \quad (1.4.2)$$

где  $f_k$  – итоговый результат нейрона (узла)  $k$ ;

$X$  – вектор объясняющих переменных;

$g_k$  – функция, которая агрегирует результаты узла  $k$  выходного слоя;

$Z_m$  – результат скрытого слоя  $m$ ;

$\sigma(v) = \frac{1}{1+e^{-v}}$  – логистическая сигмоида;

$T_k$  – прогноз узла  $k$  выходного слоя.

[Murphy, 2022] отмечает, что ANN могут переобучаться при анализе изображений и временных рядов. Это объясняется двумя причинами. Первая причина состоит в том, что при анализе изображений и временных рядов необходимо оценить большее количество параметров в ANN по сравнению с CNN и RNN. Второй причиной является то, что при обучении ANN не вводятся предпосылки о структуре данных: соседние пиксели изображения могут тесно коррелировать между собой, а лаговые значения временного ряда тесно коррелируют с наблюдением текущего периода. Эти предпосылки вводятся при обучении CNN и RNN, описание которых приводится далее.

*Сверточные нейронные сети (Convolutional Neural Networks, CNN)*. Прогноз CNN равен (1.4.3) [Kiranyaz et al., 2021]:

$$y_k^l = f(x_k^l), x_k^l = b_k^l + \sum_{i=1}^{N^{l-1}} conv1D(w_{ik}^{l-1}, s_i^{l-1}), \quad (1.4.3)$$

где индекс  $k$  – номер нейрона (узла);

индекс  $l$  – номер слоя;  $b_k^l$  – константа, смещение (bias);

$w_{ik}^{l-1}$  – матрица весов, ядро (kernel);  $f(\cdot)$  – функция активации;

$conv1D(w_{ik}^{l-1}, s_i^{l-1})$  – операция свертки;

$s_i^{l-1}$  – промежуточный результат на  $i$ -м нейроне  $(l-1)$ -го слоя.

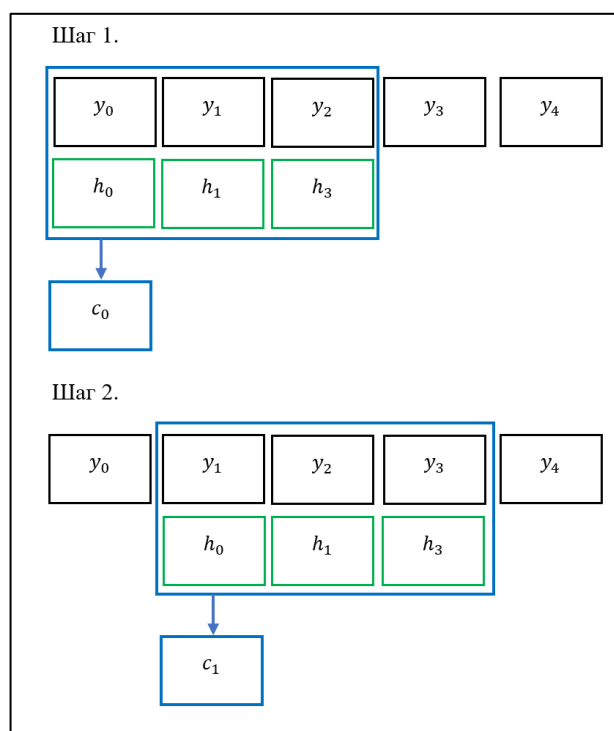
CNN имеют ряд преимуществ по сравнению с ANN: выявление локальных закономерностей с помощью операции свертки, решение проблемы переобучения через создание большего количества выборок меньшего размера, повышение скорости статистических вычислений, т.к. для обработки матрицы  $(m \times n)$  вычислительная сложность сокращается от  $\mathcal{O}(m \times n)$  до  $\mathcal{O}(k \times n)$ , где  $k$  – количество узлов сверточного слоя нейронной сети [Goodfellow et al., 2016, С. 330-331]. Для оценки одномерных CNN в настоящей диссертации применяется библиотека keras<sup>5</sup>.

На Рисунке 1.4.1 проиллюстрирована операция свертки в нейронных сетях. Пусть  $(y_0, y_1, y_2, y_3, y_4)$  является вектором целевой переменной, а  $(h_0, h_1, h_2)$  – вектором свертки.

<sup>5</sup> Conv1D / TensorFlow: site. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/layers/Conv1D](https://www.tensorflow.org/api_docs/python/tf/keras/layers/Conv1D) (дата обращения: 09.03.2024)

Первым результатом свертки является вектор  $c_0$ , который равен сумме произведений:  $c_0 = y_0h_0 + y_1h_1 + y_2h_2$ . На втором шаге свертка предоставляет значение  $c_1 = y_1h_0 + y_2h_1 + y_3h_2$ .

Таким образом на первом этапе обучения CNN двумерная матрица (например, изображение в виде пикселей) разделяется на пересекающиеся подматрицы. На втором этапе, каждая подматрица поэлементно умножается на матрицу весов, которая называется фильтром. На третьем этапе применяются объединяющие слои (pooling layer), которые преобразовывают матрицу второго шага в сводные числовые характеристики. Итоговая матрица называется картой признаков (feature map) [Goodfellow et al., 2016; Murphy, 2022].



*Рисунок 1.4.1 – Механизм работы одномерных сверточных нейронных сетей. Источник: составлено автором*

Для составления прогнозов инфляции с помощью нейронных сетей необходимо сформировать тензор, определяемый как многомерная матрица. В настоящей диссертации мы формируем трехмерный тензор, включающий три элемента: 1) количество подвыборок (batches); 2) количество наблюдений, по которым обучаются нейронные сети; 3) количество переменных (features). С помощью скользящих фильтров (sliding filters)<sup>6</sup> из каждой подвыборки входного тензора отбираются матрицы меньшей размерности. Далее через тензорное произведение (произведение Кронекера)  $\otimes$  и сверточные ядра (convolutional kernels) отобранные трехмерные матрицы преобразовываются в одномерные вектора.

<sup>6</sup> Зачастую матричная размерность скользящих фильтров составляет  $3 \times 3, 5 \times 5$ .

Стоит отметить, что в сверточных нейронных сетях недостаточно внимания уделяется закономерностям, существующим между более отдаленными наблюдениями, из-за того, что операция свертки происходит локально. Этот пробел восполняется рекуррентными нейронными сетями, описание которых приводится далее.

*Рекуррентные нейронные сети (Recurrent Neural Networks, RNN)*. На каждой итерации RNN фиксирует весовую матрицу узлов скрытых слоев (hidden state) с учетом результата предыдущего слоя нейронной сети [Cho et al., 2014; Chung et al., 2014]. Скрытые состояния  $h_t$  обновляются согласно формуле (1.4.4):

$$h_t = \begin{cases} 0, & \text{если } t = 0 \\ \phi(h_{t-1}, x_t), & \text{иначе} \end{cases} \quad (1.4.4)$$

где  $\phi(\cdot)$  – нелинейная функция;

$h_t = g(Wx_t + Uh_{t-1})$  – частный пример функции обновления состояния;

$W, U$  – матрица весов.

[Murphy, 2022] отмечает, что скрытое состояние слоя  $l$  в период  $t$ ,  $h_t^l$ , обновляется согласно методу обратного распространения во времени (1.4.5):

$$\begin{cases} h_t^l = \varphi_l(W_{xh}^l h_{t-1}^l + W_{hh}^l h_{t-1}^l + b_h^l) \\ o_t = W_{ho} h_t^l + b_o \end{cases}, \quad (1.4.5)$$

где  $W_{xh}^l$  – матрица весов, которая объединяет входные переменные  $x$  со скрытым слоем  $l$ ;

$W_{hh}^l$  – матрица весов, которая объединяет скрытый слой  $l$  со следующим скрытым слоем ( $l \in \{1, 2, \dots, L\}$ );

$W_{ho}$  – матрица весов, которая объединяет последний скрытый слой  $L$  со слоем, который содержит итоговый прогноз  $o_t$ ;

$b_h^l$  – вектор констант (bias) скрытого слоя  $l$ ;

$b_o$  – вектор констант (bias) скрытого слоя, который содержит итоговый прогноз.

Стоит отметить, что при обучении RNN с большим количеством параметров может наблюдаться незначительное изменение параметров скрытых слоев, то есть незначительное изменение градиента функции минимизации на каждом цикле обучения  $t$ . Эту проблему затухающего градиента позволяют решить модификации RNN, описание которых приводятся далее.

*Модель долгой краткосрочной памяти (Long Short-Term Memory, LSTM)*. LSTM является улучшенной формой RNN. Модификация состоит в том, что информация обрабатывается пропускными механизмами (gated mechanisms) [Hochreiter, Schmidhuber,

1997; Karpathy et al., 2015]. На каждом цикле  $t$  обучения результат  $j$ -го нейрона  $h_t^j$  формируется согласно формуле (1.4.6):

$$\left\{ \begin{array}{l} h_t^j = o_t^j \times \tanh(c_t^j) \\ o_t^j = \sigma(W_o x_t + U_o h_{t-1} + V_o c_t)^j \\ c_t^j = f_t^j c_{t-1}^j + i_t^j \tilde{c}_t^j \\ \tilde{c}_t^j = \tanh(W_c x_t + U_c h_{t-1})^j \\ f_t^j = \sigma(W_f x_t + U_f h_{t-1} + V_f c_{t-1})^j \\ i_t^j = \sigma(W_i x_t + U_i h_{t-1} + V_i c_{t-1})^j \end{array} \right. , \quad (1.4.6)$$

где  $j$  – индекс узла нейронной сети;

$c_t^j$  – ячейка памяти (memory cell);

$o_t^j$  – результирующий пропускной механизм (output gate);

$t$  – индекс цикла обучения;

$f_t^j$  – пропускной механизм отсеивания информации (forget gate);

$\tilde{c}_t^j$  – обновление ячейки памяти;

$i_t^j$  – пропускной механизм фиксации информации (input gate).

*Управляемый рекуррентный блок (Gated Recurrent Unit, GRU)*. Прогноз нейронной сети GRU равен:

$$\left\{ \begin{array}{l} h_t^j = (1 - z_t^j) h_t^j + z_t^j \tilde{h}_t^j \\ \tilde{h}_t^j = \tanh(W x_t + U(r_t \odot h_{t-1}))^j \\ z_t^j = \sigma(W_z x_t + U_z h_t)^j \\ r_t^j = \sigma(W_r x_t + U_r h_{t-1})^j \end{array} \right. , \quad (1.4.7)$$

где  $j$  – индекс узла нейронной сети;

$t$  – индекс цикла обучения;

$r_t^j$  – пропускной механизм обнуления информации (reset gate);

$z_t^j$  – пропускной механизм обновления информации (update gate);

$\tilde{h}_t^j$  – потенциальный результат (candidate activation);

$\odot$  – поэлементное умножение матриц.

GRU отличается от LSTM тем, что ячейка памяти  $c_t^j$  заменяется на пропускной механизм обнуления информации  $r_t^j$ . В научных исследованиях получено, что по сравнению с авторегрессией, ARIMA, векторной авторегрессией, моделью случайного блуждания, кривой Филлипса, динамическими факторными моделями более точные прогнозы инфляции предоставляют полносвязные [Moshiri, Cameron, 2000; Nakamura, 2005; Pavlov, 2020; Szafranek, 2019; Chakraborty, Joseph, 2017), сверточные [Aanes, Gullien, 2018], рекуррентные и байесовские нейронные сети [Hauzenberger et al., 2022], модели долгой

краткосрочной памяти [Paranhos, 2021; Almosova, Andresen, 2022; Longo, Soltanieh-Na, 2023] и управляемого рекуррентного блока [Barkan et al., 2022].

Преимущество нейросетевых методов прогнозирования по сравнению с базовыми моделями заключается в возможности более точной аппроксимации непрерывных функций, а также в учете нелинейных взаимосвязей между переменными. В то же время нейросетевые методы имеют ряд недостатков. Так, полносвязные нейронные сети не учитывают лаговую структуру переменных, а именно тот факт, что информация за предыдущий момент времени является важным фактором при составлении прогнозов на последующий горизонт. Этот пробел учитывается в RNN, которые последовательно обрабатывают статистические данные. А именно, вектор скрытого представления предыдущей итерации  $h_{t-1}$  учитывается в следующем цикле обучения рекуррентной нейронной сети  $h_t$ . Также RNN по сравнению с ANN имеет ячейку памяти (memory cell), которая позволяет учесть долгосрочные закономерности между переменными. В свою очередь, преимущество CNN по сравнению с ANN состоит в обработке многомерных матриц (тензоров) с помощью ядер (kernel), агрегирующих фильтров, объединяющих слоев (pooling layers).

Подводя итог анализа литературных источников, проведенного в параграфах 1.3 и 1.4, можно сделать вывод о том, что в научных исследованиях, посвященных применению методов машинного обучения для прогнозирования инфляции в России, недостаточно внимания уделяется адаптивному, упорядоченному и поправочному градиентным бустингам, сверточным и рекуррентным нейронным сетям, моделям управляемого рекуррентного блока и долгой краткосрочной памяти. Данный пробел восполняется в настоящей диссертации через прогнозирование инфляции в России на основе модифицированных ансамблевых и нейросетевых методов машинного обучения, а также их комбинаций.

### **1.5. Разработка моделей комбинирования для прогноза инфляции в России**

В главе 1 систематизированы научные исследования, в которых применяются следующие методы прогнозирования инфляции: 1) эконометрические (параграф 1.1); 2) байесовские (параграф 1.2); 3) ансамблевые (параграф 1.3); 4) нейросетевые (параграф 1.4). Помимо прогнозирования инфляции модифицированными ансамблевыми и нейросетевыми методами новизна настоящей диссертации заключается в построении моделей, которые

комбинируют прогнозы градиентного бустинга и нейронных сетей. Прогнозирование инфляции на основе комбинирования результатов множества моделей апробировано в российских и зарубежных научных исследованиях, обзор которых представлен в Таблице 1.5.1.

Таблица 1.5.1 – Обзор научных исследований, в которых применяется метод комбинирования для прогноза инфляции

Исследование	Описание исследования
[Stock, Watson, 1999]	Для прогноза инфляции в США применяются три метода комбинирования: арифметическое усреднение, использование медианного значения прогнозов моделей; установление весов согласно коэффициентам модели Ridge.
[Bjornland et al., 2008]	Для прогноза инфляции в Норвегии комбинируются модели ARIMA, динамические факторные модели, векторные авторегрессии, байесовские векторные авторегрессии, DSGE, модели коррекции ошибок. Веса для моделей устанавливаются обратно пропорционально среднеквадратической ошибке прогноза моделей.
[Stock, Watson, 2008]	Для прогноза инфляции в США применяются два метода комбинирования: арифметическое усреднение прогнозов моделей; установление весов обратно пропорционально среднеквадратической ошибке прогноза модели.
[Kapetanios, Labhard, Price, 2008]	Для прогноза инфляции в Великобритании применяются два метода комбинирования: на основе информационных критериев Акаики и Шварца, а также байесовское усреднение моделей
[Kascha & Ravazzolo, 2010]	Для прогноза инфляции в Великобритании, Новой Зеландии, Норвегии, США комбинируются оценки, полученные на основе авторегрессий (в том числе векторных) и кривой Филлипса. Веса устанавливаются: равными для всех моделей, обратно пропорционально среднеквадратическое ошибке прогноза модели, как отношение логарифма прогноза модели к сумме логарифмов прогнозов всех моделей.
[Koop, Korobilis, 2012]	Для прогноза инфляции в США применяется динамическое усреднение моделей с байесовским оцениванием.
[Ogunc et al., 2013]	Для прогноза инфляции в Турции комбинируются оценки динамических факторных моделей, векторных авторегрессий (в том числе байесовских) и кривых Филлипса. Применяются следующие методы комбинирования: арифметическое усреднение, усеченное арифметическое усреднение, на основе медианного значения и с весами, обратно пропорциональными среднеквадратической ошибке прогнозов.
[Андреев, 2016]	Для прогноза инфляции в России применяется метод комбинирования, при котором веса устанавливаются обратно пропорционально среднеквадратической ошибке прогноза моделей векторных авторегрессий и линейных регрессий.
[Chakraborty, Joseph, 2017]	Для прогноза инфляции в Великобритании комбинируются оценки метода опорных векторов и нейронных сетей.

Источник: составлено автором.

В академических работах, посвященных прогнозированию макроэкономических показателей, отмечается, что метод комбинирования предоставляет более точные прогнозы по сравнению с оценками отдельных моделей [Steel, 2020; Wang et al., 2023]. Это может объясняться тем, что метод комбинирования более устойчив к структурным сдвигам и в меньшей степени подвержен проблеме смещения из-за неверной спецификации, присущей отдельным моделям [Timmermann, 2006; Андреев, 2016].

Теоретическое доказательство преимущества метода комбинирования по сравнению с отдельными моделями в задачах прогнозирования получено в ряде научных исследований [Smith, Wallis, 2009; Claeskens et al., 2016; Chan, Pauwels, 2018]. [Smith, Wallis, 2009] аналитически разрешили загадку комбинирования прогнозов (forecast combination puzzle). Сложные методы комбинирования могут иметь более высокую дисперсию прогнозов по сравнению с методом комбинирования с равными весами. Причиной более высокой дисперсии прогнозов может быть то, что при прогнозировании более сложными методами комбинирования могут возникнуть ошибки при оценке весов отдельных моделей (estimation errors). Это мнение разделяют [Claeskens et al., 2016]. В свою очередь, [Chan et al., 2018] обобщают выводы [Smith, Wallis, 2009; Claeskens et al., 2016], аналитически выводя необходимые и достаточные условия, позволяющие решить загадку комбинирования прогнозов.

В научной литературе раскрывается экономическое содержание метода комбинирования в задаче прогнозирования инфляции. В частности, [Cogley, Sargent, 2005] разработали теоретическую модель, согласно которой деятельность монетарного регулятора может основываться на комбинации из трех уравнений, позволяющих прогнозировать уровни инфляции и безработицы:

$$\begin{aligned} y_{t+1} &= \gamma_0 + \gamma_1 u_{t+1} + \gamma_2 u_t + \gamma_3 u_{t-1} + \gamma_4 y_t + \gamma_5 y_{t-1} + \gamma_6 y_{t-2} + \gamma_7 y_{t-3} + \eta_{t+1}^1 \\ \Delta y_{t+1} &= \delta_1 g_{t+1} + \delta_2 g_t + \delta_3 g_{t-1} + \delta_4 \Delta y_t + \delta_5 \Delta y_{t-1} + \delta_6 \Delta y_{t-2} + \eta_{t+1}^2 \\ g_{t+1} &= \phi_1 (y_{t-1} - x_{t+1|t}) + \phi_2 g_t + \phi_3 g_{t-1} + \eta_{t+1}^3 \end{aligned} \quad (1.5.1)$$

где  $y_t = x_t + \xi_t$  – фактическая инфляция,  $x_t$  – трендовая инфляция,  $\xi_t \sim N(0, \sigma_\xi^2)$ ,  $g_t = (u_t - u_t^*)$  – разрыв безработицы,  $u_t$  – фактический уровень безработицы,  $u_t^*$  – естественный уровень безработицы,  $x_{t|t-1}$  – оценка трендовой инфляции в период  $t$  с учетом решений центрального банка, принятых в период  $t - 1$ ,  $\eta_t^i \sim N(0, \sigma_\eta^2)$  – ошибки  $i$ -й регрессии,  $\Delta$  – оператор разности первого порядка,  $(L)$  – лаговый оператор.

Первой задачей центрального банка является оценка параметров каждой модели системы (1.5.1).

Второй задачей центрального банка в рамках рассматриваемой теоретической модели является определение весов данных зависимостей в их комбинации согласно байесовскому подходу:

$$\alpha_{it} = \frac{w_{it}}{w_{1t} + w_{2t} + w_{3t}}$$

$$\log(w_{it+1}) = \log(w_{it}) + \log\left(p(Y_{it+1}|X_{it+1}, \theta_i, \sigma_i^2)\right) - \log\left(\frac{p(\theta_i, \sigma_i^2|Z_i^{t+1})}{p(\theta_i, \sigma_i^2|Z_i^t)}\right), \quad (1.5.2)$$

где  $i \in \{1, 2, 3\}$  – индекс регрессии системы (1.5.1);  $\alpha_{it}$  – нормированный вес  $i$ -й регрессии в комбинации моделей;  $w_{it}$  – исходный вес  $i$ -й регрессии в комбинации моделей;  $p(Y_{it+1}|X_{it+1}, \theta_i, \sigma_i^2)$  – логарифм условной функции правдоподобия;  $\theta_i$  – вектор параметров  $i$ -ой регрессии;  $\sigma_i^2$  – дисперсия ошибок  $i$ -й регрессии;  $p(\theta_i, \sigma_i^2|Z_i^{t+1})$  – апостериорное распределение параметров  $i$ -ой регрессии с учетом статистических данных, доступных на период  $t + 1$ ,  $Z_i^{t+1} \in \{(X_1, Y_1), (X_2, Y_2), \dots, (X_{t+1}, Y_{t+1})\}$ ;  $X_{t+1}$  – матрица объясняющих переменных;  $Y_{t+1}$  – объясняемая переменная.

Далее, третьей задачей центрального банка является минимизация совместной функции ошибки трех моделей:

$$L_E = \alpha_{1t}L(M_1) + \alpha_{2t}L(M_2) + \alpha_{3t}L(M_3) = E_t \sum_{j=0}^{\infty} \beta^j (S'_{E,t+j} Q'_{E,t} S_{E,t+j} + x'_{t+j|t-1} R x_{t+j|t-1}),$$

$$\text{где } Q_{E,t} = \begin{bmatrix} \alpha_{1t} M'_{s_1} Q M_{s_1} & 0 & 0 \\ 0 & \alpha_{2t} M'_{s_2} Q M_{s_2} & 0 \\ 0 & 0 & \alpha_{3t} M'_{s_3} Q M_{s_3} \end{bmatrix}, \quad M_{s_1} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix},$$

$$M_{s_2} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & u_t^* \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix}, \quad M_{s_3} = \begin{bmatrix} 1 & 0 & 0 & u_t^* \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad Q = \begin{bmatrix} 1 & 0 \\ 0 & \lambda \end{bmatrix}, \quad R = 0.001,$$

$L(M_i)$  – функция минимизации  $i$ -й модели,  $\beta$  – фактор дисконтирования,  $E_t$  – математическое ожидание;

$S_t^1 = [u_t, u_{t-1}, y_t, y_{t-1}, y_{t-2}, y_{t-3}, 1]'$ ,  $S_t^2 = [g_t, g_{t-1}, y_t, y_{t-1}, y_{t-2}, y_{t-3}, 1]'$ ,  $S_t^3 = [g_t, g_{t-1}, y_t, 1]'$  – вектор переменных состояния в первой, второй, третьей модели системы (1.5.1).

Наше исследование дополняет и развивает исследование [Cogley, Sargent, 2005], предполагая, что для прогнозирования инфляции и безработицы монетарные власти способны применять не три разновидности кривой Филлипса, а три группы обширных моделей: эконометрические модели, ансамблевые методы и нейросетевые методы машинного обучения. Использование методов машинного обучения в комбинации моделей обусловлено тем, что инфляция может иметь нелинейные взаимосвязи с показателями экономической активности. Это предположение имеет теоретическое обоснование. В

частности, [Harding et al., 2022] объясняют нелинейную взаимосвязь между инфляцией и выпуском тем, что спрос на конечные товары характеризуется квази-ломанной (quasi-kinked) функцией:

$$\frac{Y_{f,t}}{Y_t} = \frac{1}{1+\psi_p} \left( \frac{P_{f,t}}{P_t v_t^p} \right)^{\varepsilon_p} + \frac{\psi_p}{1+\psi_p}, \quad (1.5.3)$$

где  $Y_{f,t}$  – объем выпуска промежуточных товаров;  $Y_t$  – объем выпуска конечных товаров;  $P_{f,t}$  – уровень цен на промежуточные товары;  $P_t$  – уровень цен на конечные товары;  $v_t^p$  – множитель Лагранжа в оптимизационной задаче фирм, которые производят конечные товары;  $\varepsilon_p = \frac{\phi_p(1+\psi_p)}{1-\phi_p}$ ;  $\phi_p = 1 + \theta_p$  – наценки фирм, которые производят промежуточные товары;  $\psi_p < 0$  означает, что (1) снижение цен приводит к меньшему росту спроса на товары, (2) повышение цен приводит к более высокому сокращению спроса на товары по сравнению с параметром  $\psi_p = 0$ , который предполагает постоянную эластичность спроса по цене, то есть линейную взаимосвязь между спросом на промежуточные товары и их ценами. Также при  $\psi_p = 0$  рост предельных издержек на 1 процент приводит приблизительно к 1-процентному росту цен на промежуточные товары:

$$p_f^{opt} = \phi_p mc, \quad (1.5.4)$$

где  $mc$  – предельные издержки фирм, которые производят промежуточные товары;  $p_f^{opt}$  – оптимальный уровень цен на промежуточные товары.

В случае  $\psi_p < 0$  наблюдается нелинейная взаимосвязь между уровнем цен на промежуточные товары и предельными издержками:

$$p_f^{opt} \left( 1 - \frac{\theta_p \psi_p}{1+\psi_p+\theta_p \psi_p} (p_f^{opt})^{\frac{(1+\theta_p \psi_p)(1+\psi_p)}{\theta_p}} \right) = \frac{(1+\theta_p \psi_p)(1+\psi_p)}{1+\psi_p+\theta_p \psi_p} mc. \quad (1.5.5)$$

В работе [Harding et al., 2023] получено, что квази-ломанный спрос на товары приводит к нелинейной взаимосвязи между уровнем цен и объемом выпуска:

$$\left\{ \begin{array}{l} \frac{1+\phi_p \epsilon_p}{1+\epsilon_p} p_t^* \gamma_{1,t}^p = p_t^* \gamma_{2,t}^p + \frac{\epsilon_p (\phi_p - 1)}{1+\epsilon_p} \left( p_t^* \frac{\phi_p (1+\epsilon_p)}{\phi_p - 1} + 1 \right) \gamma_{3,t}^p \\ \gamma_{1,t}^p = (\delta_f^p)^{\frac{\phi_p (1+\epsilon_p)}{\phi_p - 1}} y_t + (\beta \gamma^{1-\sigma}) \xi_p E_t \frac{\xi_{t+1}}{\xi_t} \left( \frac{\pi^{1-l_p} \pi_t^{l_p}}{\pi_{t+1}} \right)^{-\frac{1+\phi_p \epsilon_p}{\phi_p - 1}} \gamma_{1,t+1}^p \\ \gamma_{2,t}^p = (\delta_f^p)^{\frac{\phi_p (1+\epsilon_p)}{\phi_p - 1}} m c_t \epsilon_{p,t} y_t + (\beta \gamma^{1-\sigma}) \xi_p E_t \frac{\xi_{t+1}}{\xi_t} \left( \frac{\pi^{1-l_p} \pi_t^{l_p}}{\pi_{t+1}} \right)^{-\frac{\phi_p (1+\epsilon_p)}{\phi_p - 1}} \gamma_{2,t+1}^p \\ \gamma_{3,t}^p = y_t + (\beta \gamma^{1-\sigma}) \xi_p E_t \frac{\xi_{t+1}}{\xi_t} \left( \frac{\pi^{1-l_p} \pi_t^{l_p}}{\pi_{t+1}} \right) \gamma_{3,t+1}^p \end{array} \right. , \quad (1.5.6)$$

где  $\xi_t$  – вероятность того, что фирмы сохранят цены в период  $t$  (параметр ценовой жесткости);  $\phi_p$  – наценки на промежуточные товары;  $p$  – индекс (субиндекс), который означает, что параметр модели относится к параметрам в устойчивом состоянии;  $\pi$  – уровень инфляции в устойчивом состоянии;  $\delta$  – норма амортизации; при  $\epsilon_p > 0$  рост предельных издержек на 1 процент приводит к росту цен на промежуточные товары меньше, чем на 1 процент;  $m c_t$  – предельные издержки фирм, которые производят промежуточные товары;  $f$  – индекс фирм, которые производят промежуточные товары;  $y_t$  – объем выпуска конечных товаров;  $\gamma$  – темп роста выпуска конечных товаров в устойчивом состоянии;  $\beta$  – фактор дисконтирования;  $p_t^* = \frac{P_t^*}{P_t}$  – отношение оптимального уровня цен на промежуточные товары к общему уровню цен;  $\epsilon_{p,t}$  – шок предельных издержек фирм, которые производят промежуточные товары;  $\pi_{t+1}$  – уровень инфляции в период  $t + 1$ ;  $l_p$  – параметр, который определяет влияние инфляции предыдущего периода  $t - 1$  на инфляцию текущего периода  $t$ ;  $\xi_p$  – вероятность того, что фирмы будут сохранять цены на товары.

Согласно третьему уравнению системы (1.5.6) наблюдается нелинейная взаимосвязь между уровнем цен  $p_t^*$  и совместным взаимодействием предельных издержек  $m c_t$ , объема выпуска конечных товаров  $y_t$  и шока предельных издержек  $\epsilon_{p,t}$ .

Таким образом, применение методов машинного обучения и их комбинаций в прогнозировании инфляции России обосновано двумя причинами: 1) центральный банк принимает решения в денежно-кредитной политике на основе множества моделей прогнозирования цен и показателей экономической активности (объем выпуска, уровень безработицы) [Cogley, Sargent, 2005]; 2) может наблюдаться нелинейная взаимосвязь между ценами и предельными издержками, а также объемом выпуска [Harding et al., 2022; 2023].

В ряде центральных банков метод комбинирования применяется для прогноза инфляции. Это имеет место, в частности, в Великобритании [Kapetanios et al., 2008; Charkaborty, Joseph. 2017], еврозоне [Hubrich, Skudelny, 2017], Норвегии [Bjornland et al., 2008; Kascha, Ravazzolo, 2010], России [Андреев, 2016; Semiturkin, Shevelev, 2023], США [Fulton, Hubrich, 2021], Турции [Ogunc et al., 2013].

Наше исследование отличается от [Андреев, 2016; Semiturkin, Shevelev, 2023] тем, что комбинируются ансамблевые и нейросетевые методы машинного обучения. Также мы дополняем [Андреев, 2016; Semiturkin, Shevelev, 2023] тем, что комбинирование прогнозов основывается на доверительном множестве моделей (Model Confidence Set, MCS [Hansen et al., 2011]). В частности, мы используем следующий *Алгоритм 1*.

*Алгоритм 1 – составление доверительного множества моделей.*

1. Устанавливается множество всех моделей  $\mathcal{M} = \mathcal{M}_0$ , уровень доверия  $\gamma = 1 - \alpha$ , где  $\alpha$  – уровень статистической значимости.
2. Тестируются гипотезы о равной прогнозной точности:

Нулевая гипотеза  $H_{0,M}: c_{ij} = 0$  для всех моделей  $i, j = 1, 2, \dots, m$ .

Альтернативная гипотеза  $H_{A,M}: c_{ij} \neq 0$  для всех моделей  $i, j = 1, 2, \dots, m$ .

где  $c_{ij} = \mathbb{E}[d_{ij}] = \mathbb{E}[l_{i,t} - l_{j,t}] = \mathbb{E}[l(Y_t, \hat{Y}_{i,t}) - l(Y_t, \hat{Y}_{j,t})]$ ;

$\mathbb{E}[\cdot]$  – оператор математического ожидания;

$l(Y_t, \hat{Y}_{i,t})$  – функция минимизации модели  $i$ ;

$Y_t$  – наблюдения целевой переменной;  $\hat{Y}_{i,t}$  – прогнозы модели  $i$ .

Для тестирования гипотез используется статистика (1.5.7):

$$T_{R,M} = \max_{i,j \in M} |t_{ij}| = \max_{i,j \in M} \left| \frac{\bar{d}_{ij}}{\sqrt{\widehat{var}(\bar{d}_{ij})}} \right|, \quad (1.5.7)$$

где  $\widehat{var}(\cdot)$  – выборочная дисперсия;

$\bar{d}_{ij} = \frac{1}{n} \sum_{i=1}^n d_{ij,t}$  – среднее значение разности функции минимизации моделей  $i$  и  $j$ .

3. При заранее установленном уровне доверия  $\gamma$  составляется множество оптимальных моделей  $\mathcal{M}_\gamma$ . А Это достигается путем исключения наименее точных моделей из множества  $\mathcal{M}_0$  согласно формуле (1.5.8):

$$e_{R,M} = \underset{i}{\operatorname{argmax}} \left\{ \sup_j \left( \frac{\bar{a}_{ij}}{\sqrt{\widehat{\operatorname{var}}(\bar{a}_{ij})}} \right) \right\}. \quad (1.5.8)$$

Таким образом, в настоящей работе составляются следующие группы моделей: 1) модели градиентного бустинга и случайного леса; 2) нейронные сети; 3) множество оптимальных моделей [Hansen et al., 2011].

Следуя российской и зарубежной практике прогнозирования инфляции (см. Таблице 1.5.1), внутри каждого множества веса устанавливаются: (1) равными<sup>7</sup> для всех моделей (1.5.9), (2) обратно пропорционально среднеквадратической ошибке прогноза (1.5.10):

$$f_{t+h}^c = \frac{1}{M} \sum_{m=1}^M f_m. \quad (1.5.9)$$

$$f_{t+h}^c = \sum_{m=1}^M f'_m \times \frac{\hat{\sigma}^{-2}(m)}{\sum_{k=1}^K \hat{\sigma}^{-2}(k)}. \quad (1.5.10)$$

где  $f_{t+h}^c$  – прогноз комбинации моделей;  $h$  – горизонт прогноза;

$f_m$  – прогноз модели  $m$ ,  $m \in \{1, 2, \dots, M\}$ ; индекс  $c$  – номер множества моделей  $c \in \{1, 2, 3\}$ ;  $f'_m$  – транспонированный вектор прогнозов модели  $m$ ;

$\hat{\sigma}^2(k)$  – среднеквадратичная ошибка прогноза модели  $k$ .

Таблица 1.5.2<sup>8</sup> содержит информацию по методам комбинирования моделей градиентного бустинга и случайного леса, нейронных сетей.

<sup>7</sup> [Timmermann, 2006] по результатам изучения 15-ти методов комбинирования пришел к выводу о том, что усреднение является одним из более точных методов комбинирования прогнозов. Данную точку зрения разделяют [Wang et al., 2023].

<sup>8</sup> Стоит отметить, что одним из способов агрегирования прогнозов множества нейронных сетей является дистилляция [Hinton et al., 2015]. В задаче классификации дистилляция включает два этапа. На первом этапе обучается нейронная сеть с большим числом параметров (количество скрытых слоев, количество узлов/нейронов в каждом слое) и сохраняются прогнозы шансов (odds) для наблюдения  $i$ :  $p_i = \frac{e(\frac{v_i}{T})}{\sum_j e(\frac{v_j}{T})}$ , где

$v_i \in \{0, 1\}$  – вероятность,  $T$  – параметр сжатия вероятностей. На втором этапе обучается нейронная сеть с малым числом параметров на основе функции минимизации, которая включает прогнозы нейронной сети с

большим числом параметров:  $\frac{\partial c}{\partial z_i} = \frac{1}{T} (q_i - p_i) = \frac{1}{T} \left( \frac{e(\frac{z_i}{T})}{\sum_j e(\frac{z_j}{T})} - \frac{e(\frac{v_i}{T})}{\sum_j e(\frac{v_j}{T})} \right)$ , где  $q_i$  – прогнозы нейронной сети с

малым числом параметров.

Таблица 1.5.2 – Комбинации ансамблевых и нейросетевых методов машинного обучения

Комбинация моделей	Состав моделей и метод комбинирования
CLARA-SA, CLARA-BG	Ансамблевые методы: CatBoost, LightGBM, AdaBoost, <b>R</b> andom Forest, XGBoost
CARLSON-SA, CARSLON-BG	Нейросетевые методы: Convolutional, Artificial, <b>R</b> ecurrent Long-Short Term Memory, Gated Combinati <b>O</b> N
MCS-SA, MCS-BG	Доверительное множество моделей [Hansen et al., 2011]

*Примечание: «MCS» – доверительное множество моделей (Model Confidence Set), «SA» – среднее арифметическое (Simple average); «BG» – веса моделей определяются обратно пропорционально ошибке прогноза [Bates, Granger, 1969]. Источник: составлено автором.*

Наряду с методологическими аспектами прогнозирования значимым элементом модельного аппарата является формирование множества объясняющих переменных, которое имеет научное обоснование и позволит повысить точность моделей, чему посвящена следующая глава 2.

## **Глава 2. Теоретические подходы к анализу макроэкономических факторов инфляции**

Данная глава посвящена теоретическим механизмам и эмпирическим оценкам влияния макроэкономических показателей на инфляцию. В параграфе 2.1 изучаются механизмы влияния показателей рынка труда на динамику цен. В параграфе 2.2 анализируются показатели производственного сектора, которые влияют на инфляцию. Параграф 2.3 посвящен показателям финансового сектора, которые взаимосвязаны с инфляцией. В параграфе 2.4 рассматриваются научные работы, в которых подчеркивается важность учета инфляционных ожиданий при прогнозе динамики цен. В параграфе 2.5 подводятся итоги по обзору научных работ, что позволит сформировать множество объясняющих переменных, которое основано на теоретических механизмах и эмпирических результатах исследований, посвященных инфляционным процессам.

### **2.1. Анализ динамики цен на основе показателей рынка труда**

В экономической теории принято считать, что А. Филлипс впервые предложил оценивать динамику цен на основе показателей рынка труда. На статистических данных по Великобритании за период с 1861 г. по 1957 г. было выявлено, что темп роста заработных плат замедляется при росте уровня безработицы [Phillips, 1958]. Это может объясняться следующим трансмиссионным механизмом: снижение агрегированного спроса → снижение спроса на труд → повышение уровня безработицы → безработному населению сложнее трудоустроиться и вести переговоры с фирмами, так как у фирм имеется множество вариантов того, кого принять на работу → чтобы трудоустроиться безработное население соглашается на более низкую заработную плату → фирмы снижают заработные платы.

Помимо Великобритании в 1960-х гг. взаимосвязь между темпом роста заработных плат и уровнем безработицы была изучена П. Самуэльсоном и Р. Солоу на примере США [Samuelson, Solow, 1960]. Однако их результаты отличались от тех, которые получил А. Филлипс. Одной из причин различных результатов между двумя странами могло быть то, что в Великобритании по сравнению с США профсоюзы имели более высокую переговорную силу. П. Самуэльсон и Р. Солоу модифицировали кривую Филлипса через

замену темпов роста заработных плат на темпы роста общего уровня цен. Они выявили, что нулевая инфляция достигается при уровне безработицы 5,5%.

Следующую модификацию кривой Филлипса предложил М. Фридман [Friedman, 1968], заменив темпы роста номинальной заработной платы на темпы роста реальной заработной платы. Это объясняется тем, что в исходной кривой Филлипса предполагается стабильная динамика цен, которая соответствует прогнозам работников, и поэтому не разделяются между собой номинальная и реальная заработные платы. Однако в трансмиссионном механизме кривой Филлипса уровень занятости определяется реальной заработной платой: рост агрегированного спроса → фирмы будут увеличивать объем выпуска → рост спроса на труд → безработное население будет трудоустраиваться при ставке номинальной заработной платы, которая была установлена до роста агрегированного спроса. Однако цены на товары и услуги меняются быстрее, чем цены на факторы производства. Это означает, что уровень занятости повышался при снижении реальной заработной платы, так как работники предполагали ценовую стабильность. Реальная заработная плата начнет расти тогда, когда после роста агрегированного спроса и общего уровня цен работники будут пересматривать условия контрактов с работодателями из-за снижения покупательной способности номинальных трудовых доходов.

Помимо замены номинальной заработной платы на реальную заработную плату М. Фридман предложил интерпретировать выводы кривой Филлипса с учетом естественного уровня безработицы [Friedman, 1968]. Естественным является уровень безработицы, при котором реальные заработные платы растут с темпом, который поддерживает технологическое развитие, инвестиции в основной капитал на долгосрочном уровне. Если уровень безработицы ниже ее естественного уровня, тогда будет наблюдаться избыточный спрос на труд, что приведет к росту реальных заработных плат. Если уровень безработицы выше ее естественного уровня, тогда избыточное предложение труда приведет к снижению реальной заработной платы, так как номинальная заработная плата будет расти меньше, чем общий уровень цен.

Часть идей М. Фридмана также разделяет Дж. Тобин: предпосылки кривой Филлипса соблюдаются в краткосрочной перспективе и при условии равенства номинальной и реальной заработных плат [Tobin, 1972]. Уровень безработицы будет снижаться с ростом агрегированного спроса, что будет создавать разрыв между фактической и ожидаемой реальной заработными платами. В долгосрочной перспективе предполагается наличие естественного уровня безработицы, при котором соблюдаются два условия: 1) рост

реальной заработной платы соответствует росту производительности труда; 2) текущая реальная заработная плата равна ожидаемой заработной плате. Эти два условия означают, что естественным является уровень безработицы, который ассоциируется с нулевым ростом общего уровня цен и заработной платы. Однако Дж. Тобин отмечал, что уровень безработицы с нулевой инфляцией не является оптимальной, естественной величиной. Объясняется это тем, что в экономике наблюдается инфляция даже при благоприятных условиях рынка труда, когда трудовые возможности соответствуют потребностям наемных работников [Tobin, 1972].

Взаимосвязь между темпом роста заработной платы и уровнем безработицы может быть выражена уравнением (2.1.1) [Вереникин, 2011]:

$$\frac{\dot{w}}{w} = \frac{h(\varphi(u)-u)}{w^*+g^{-1}(\varphi(u)-u)}, \quad (2.1.1)$$

где  $\frac{\dot{w}}{w}$  – темп роста заработной платы;

$w^*$  – равновесная ставка заработной платы;

$u = \frac{U}{U+L}$  – уровень безработицы;  $U$  – численность безработного населения;  $L$  – численность рабочей силы;

$v \equiv \varphi(u) = \frac{V}{L+U}$  – зависимость уровня вакантных мест от уровня безработицы  $u$ ;

$g^{-1}(\varphi(u) - u)$  – обратная функция избыточного спроса на труд.

На втором этапе формула (2.1.1) дополняется естественным уровнем безработицы:

$$\frac{\dot{w}}{w} = -h(u - u^*), \quad (2.1.2)$$

где  $u^*$  – естественный уровень безработицы, при котором наблюдается нулевая инфляция. Разрывом безработицы является отклонение уровня безработицы  $u$  от ее естественного уровня  $u^*$ .

На третьем этапе вводится предпосылка о том, что темп роста уровня цен пропорционален темпу роста заработной платы:

$$\pi_t = -\alpha(u - u^*), \quad (2.1.3)$$

где  $t$  – индекс периода;

$\pi_t = \frac{P_t - P_{t-1}}{P_{t-1}}$  – уровень инфляции;  $P_t$  – общий уровень цен.

Микроэкономическим обоснованием взаимосвязи между инфляцией и уровнем безработицы является то, что в краткосрочном периоде фирмы адаптируются к росту общего уровня цен через объем выпуска и уровень занятости, но не через цены на производимые товары. Объясняется это тем, что обновление цен сопровождается издержками изменения цен и трудовых контрактов, а также получения и обработки актуальной информации о внешних шоках, которые привели к инфляции.

Далее, рассмотрим научные работы, которые посвящены эмпирической оценке влияния уровня и разрыва безработицы на инфляцию в развитых и развивающихся странах. [Blanchard, 2016] на статистических данных по США за период с 1961 г. по 2013 г. подтвердил то, что с ростом уровня безработицы снижается инфляция. Однако в зарубежных исследованиях отмечается, что оценки кривой Филлипса на макроэкономическом и региональном уровнях могут отличаться [Hazell et al., 2022]. Объясняется это тем, что в отдельных регионах инфляция может не повышаться при росте уровня безработицы из-за специфики производства. [Hazell et al., 2022] на статистических данных по США за период с 1978 г. по 2018 г. выявили, что при исключении фиксированных эффектов по регионам и годам наблюдается положительная взаимосвязь между инфляцией и уровнем безработицы, что противоречит предпосылкам кривой Филлипса. В то же время при учете фиксированных эффектов по регионам и годам выявлена отрицательная взаимосвязь между инфляцией и уровнем безработицы.

Помимо развитых стран предпосылки кривой Филлипса также проверялись на развивающихся странах. На примере России [Гафаров, 2011] при оценке кривой Филлипса выявил, что переменная уровня безработицы имеет положительный коэффициент за период с I квартала 1999 г. по II квартал 2007 г., и отрицательный коэффициент за период с III квартала 2007 г. по I квартал 2010 г., что согласуется с предпосылками кривой Филлипса. Автор связывает положительный коэффициент при уровне безработицы со структурными изменениями в экономике России: в переходный период российские фирмы одновременно сокращали численность работников и снижали реальную заработную плату, что в условиях высокой инфляции приводило к росту уровня безработицы.

Мнение [Hazell et al., 2022] подтверждают [Аверина и др., 2018], которые оценили кривую Филлипса на региональных данных по России за период с 2000 г. по 2015 г. При оценке кривой Филлипса по 80 российским регионам получен статистически незначимый коэффициент при уровне безработицы. Этот результат авторы связывают с тем, что регионы России в значительной степени отличаются по структуре рынка труда. Для

проверки данной гипотезы авторы на основе уровня доходов на душу населения, уровня безработицы, доли экономически активного населения сформировали три кластера регионов России: 1) высокоразвитые; 2) среднеразвитые; 3) низкоразвитые. Получено, что для более и менее развитых регионов характерно статистически незначимое влияние уровня безработицы на инфляцию, а для среднеразвитых – статистически значимое отрицательное влияние, что согласуется с предпосылками кривой Филлипса.

[Орлов, Постников, 2018] разделяют мнение [Аверина и др., 2018] о том, что предпосылки кривой Филлипса могут не соблюдаться для всех регионов. На основе оценок кривой Филлипса на статистических данных по России за период с 2011 г. по 2018 г. авторы выделили три группы регионов в зависимости от характера влияния разрыва безработицы на инфляцию: 1) отрицательное (33 региона); 2) статистически незначимое (15 регионов); 3) положительное (32 региона).

В данном параграфе показатели рынка труда были выбраны в качестве факторов инфляции. Стоит отметить, что в альтернативном варианте кривой Филлипса предполагается взаимосвязь между инфляцией и показателями производственного сектора, чему посвящен следующий параграф 2.2.

## **2.2. Механизмы влияния показателей производственного сектора на инфляцию**

В предыдущем параграфе 2.1 мы выяснили, что в исходной кривой Филлипса ключевым фактором инфляции является уровень либо разрыв безработицы. В рамках кривой Филлипса в качестве альтернативы уровню безработицы могут рассматриваться показатели производственного сектора. Одним из них является разрыв выпуска, измеряемый отклонением фактического его объема от потенциального уровня.

Взаимосвязь между объемом выпуска и общим уровнем цен можно представить следующим уравнением (2.2.1) [Вереникин, 2011]:

$$d \ln(P) = \frac{\alpha}{\beta} \left( \ln Y(t) + \ln Y(0) - \frac{\beta}{\alpha} \pi(0) \right) dt, \quad (2.2.1)$$

где  $d$  – оператор дифференцирования;  $\ln(\cdot)$  – оператор логарифмирования;

$P$  – общий уровень цен;

$Y(t)$  – фактический объем валового внутреннего продукта (ВВП);

$\pi = \frac{P_t - P_{t-1}}{P_{t-1}}$  – темп роста общего уровня цен;

$\alpha$  – коэффициент при разрыве безработицы в кривой Филлипса  $\pi_t = \frac{P_t - P_{t-1}}{P_{t-1}} = -\alpha(u_t - u^*)$ ;

$\beta$  – коэффициент при разрыве безработицы в уравнении закона Оукена  $\frac{Y_t - Y^*}{Y^*} = -\beta(u_t - u^*)$ ;

$Y^*$  – потенциальный объем ВВП.

Операции интегрирования и потенцирования уравнения (2.2.1) позволяют выразить уровень цен согласно (2.2.2):

$$P(t) = P(0) \times \frac{Y(0)^{\frac{\alpha}{\beta}}}{e^{\pi(0)t}} e^{\frac{\alpha}{\beta} \int \ln Y(t) dt}, \quad (2.2.2)$$

где  $P(t)$  – уровень цен в периоде  $t$ ;  $e$  – экспонента.

Переходя от уровня цен к темпам роста цен, получим аналитическое представление взаимосвязи между уровнем инфляции и объемом валового выпуска:

$$\pi_t = \pi_{t-1} + \frac{\alpha}{\beta} \left( \frac{Y_t - Y^*}{Y^*} \right). \quad (2.2.3)$$

Помимо разрыва выпуска в научных исследованиях отмечается, что важным фактором инфляции являются предельные издержки производства [Gali, Gertler, 1999]. Обоснованием выбора данного показателя производственного сектора является предпосылка о том, что цены корректируются согласно следующей системе:

$$\begin{cases} p_t = \theta p_{t-1} + (1 - \theta) p_t^* \\ p_t^* = (1 - \beta\theta) \sum_{k=0}^{\infty} (\beta\theta)^k \mathbb{E}_t \{ m c_{t+k}^n \} \end{cases} \quad (2.2.4)$$

где  $p_t$  – общий уровень цен;

$\mathbb{E}_t$  – оператор математического ожидания;

$\theta$  – доля фирм, которые не меняют цены в период  $t$ ;

$n$  – индекс фирм;

$p_t^*$  – оптимальная цена, которую устанавливают фирмы, корректирующие цены;

$\beta$  – коэффициент дисконтирования;

$m c_{t+k}^n$  – отклонение номинальных предельных издержек от их величины в устойчивом состоянии.

Переходя от уровня цен к темпам их роста, [Gali, Gertler, 1999] приводят следующее аналитическое представление взаимосвязи между инфляцией и предельными издержками (2.2.5):

$$\pi_t = \lambda \sum_{k=0}^{\infty} \beta^k \mathbb{E}_t \{ mc_{t+k} \}, \quad (2.2.5)$$

$$\text{где } \lambda = \frac{(1-\theta)(1-\beta\theta)}{\theta}.$$

При этом [Gali, Gertler, 1999] предлагают оценивать предельные издержки отношением доли труда в выпуске  $S_t$  к эластичности выпуска по труду  $\alpha_n$ :

$$mc_t = \frac{S_t}{\alpha_n} = \frac{\frac{W_t N_t}{P_t Y_t}}{\alpha_n} = \frac{\frac{W_t N_t}{P_t A_t K_t^{\alpha_k} N_t^{\alpha_n}}}{\alpha_n}, \quad (2.2.6)$$

где  $Y_t$  – объем валового выпуска;

$A_t$  – параметр технологического развития;

$K_t$  – запасы физического капитала;  $\alpha_k$  – эластичность выпуска по капиталу;

$W_t$  – ставка реальной заработной платы;  $N_t$  – численность рабочей силы.

Далее приведем научные работы, в которых применяются показатели производственного сектора для оценки кривой Филлипса и прогнозирования инфляции в развитых и развивающихся странах.

В работе [Stock, Watson, 1999] на статистических данных по США за период с 1970 г. по 1996 г. получено, что кривая Филлипса точнее прогнозирует инфляцию, если вместо уровня безработицы использовать показатели производственного сектора: уровень загрузки производственных мощностей; оборот розничной торговли; интегральный индекс деловой активности.

[Мухин, 2010] применил разрыв выпуска при оценке кривой Филлипса для России. При этом потенциальный уровень выпуска получен на основе тренда фильтра Ходрика-Прескотта. На квартальных данных за период с 2000 г. по 2007 г. получен статистически значимый положительный коэффициент при разрыве выпуска, что согласуется с предпосылками кривой Филлипса.

[Соколова, 2014] при оценке кривой Филлипса также применила фильтр Ходрика-Прескотта для оценки потенциального уровня выпуска в России. На ежемесячных данных за период с июля 1999 г. по март 2013 г. получен статистически значимый положительный коэффициент при разрыве выпуска.

[Зубарев, 2018] расширяет подход исследований [Мухин, 2010; Соколова, 2014], оценивая влияние разрыва выпуска на три показателя инфляции: индекс потребительских цен (далее, ИПЦ); дефлятор ВВП; дефлятор ВВП без учета экспорта. На квартальных данных по России за период с I квартала 2000 г. по III квартал 2014 г. получено, что разрыв выпуска имеет статистически значимое положительное влияние только на дефлятор ВВП, в котором не учитывается экспорт.

В отличие от [Мухин, 2010; Соколова, 2014; Зубарев, 2018] в исследовании [Хабибуллин, 2019] применяется байесовский подход к оценке разрыва выпуска. При использовании ежеквартальных данных показателем производственного сектора является ВВП, а в ежемесячных данных – индекс промышленного производства. Однако на статистических данных за период с I квартала 2000 г. по IV квартал 2018 г., а также с января 2003 г. по декабрь 2018 г. получено, что разрыв выпуска не повышает точность прогнозирования российской инфляции.

[Saul, 2021] дополняет [Хабибуллин, 2019], оценивая влияние на инфляцию в России разрыва не внутреннего, а мирового выпуска. На статистических данных за период с I квартала 2002 г. по II квартал 2020 г. получено, что точность моделей с учетом разрыва мирового выпуска не превышает точность моделей случайного блуждания. Полученный результат автор связывает с низкой долей России в мировой цепочке добавленной стоимости, что снижает влияние мирового выпуска на инфляцию в российской экономике.

Актуальность оценки кривой Филлипса для изучения инфляции подтвердилась в период пандемического кризиса. [Blanchard, Bernanke, 2023] отмечают, что инфляция во время и после пандемического шока повышалась из-за ряда причин: 1) рост цен на сырьевые товары; 2) рост потребительского спроса на товары длительного пользования; 3) задержек в логистических поставках, которые имели следствием дефицит производственных ресурсов в промышленных отраслях. Для объяснения причин повышения инфляции из-за пандемического шока предложена модель, которая состоит из четырех уравнений. В рамках первого уравнения определяется номинальная заработная плата:

$$w = p^e + w^A + \beta x, \quad (2.2.7)$$

где  $w$  – номинальная заработная плата;

$p^e$  – ожидаемый общий уровень цен;

$x$  – индикатор активности на рынке труда, которая оценивается отношением уровня вакансий к уровню безработицы<sup>9</sup>;

$w^A$  – реальная заработная плата, которую стремятся получить наемные работники в долгосрочном периоде, характеризуемая следующим уравнением:

$$w_t^A = \alpha w_{t-1}^A + (1 - \alpha)(w_{t-1} - p_{t-1}) + z_w, \quad (2.2.8)$$

где  $z_w$  – шок долгосрочной реальной заработной платы.

Темп роста реальной заработной платы определяется третьим уравнением:

$$w_t - w_{t-1} = (p^e - p_{t-1}) + \alpha(p_{t-1} + p_{t-1}^e) + \beta(x_t - \alpha x_{t-1}) + z_w, \quad (2.2.9)$$

где  $(p^e - p_{t-1})$  – отклонение ожидаемого уровня инфляции от уровня цен предыдущего периода;

$(p_{t-1} + p_{t-1}^e)$  – корректировка номинальной заработной платы на неожиданное повышение инфляции.

Уровень цен меняется согласно четвертому уравнению:

$$p_t - p_{t-1} = (w_t - w_{t-1}) + (z_p - z_{p-1}), \quad (2.2.10)$$

где  $p_t = w_t + z_p$  – общий уровень цен;  $z_p$  – инфляционный шок, не связанный с заработными платами: скачок цен на сырьевые товары, перебои логистических поставок.

На статистических данных по США за период с I квартала 1990 г. по IV квартал 2019 г. получено, что номинальная заработная плата повышается при росте двух показателей: индикатора состояния рынка труда и инфляционных ожиданий профессиональных аналитиков на следующие 12 месяцев. Данный результат означает, что соблюдаются предпосылки кривой Филлипса в ее исходной версии с темпами роста заработных плат. Если рассматривать переход от номинальной заработной платы к индексу потребительских цен (далее, ИПЦ), то можно отметить эмпирические выявленную закономерность, согласно которой повышению инфляции способствует рост четырех показателей: номинальных заработных плат, цен на продовольственные товары, цен на энергоносители и совокупной факторной производительности. О. Бланшар и Б. Бернанке отмечают, что рост цен на сырьевые товары имеет два трансмиссионных канала влияния на инфляцию: через рост

---

<sup>9</sup> Уровень вакансий определяется как отношение числа вакансий к численности занятого населения. Например, если индикатор рынка труда равен 2, это означает, что две вакансии приходятся на одного безработного гражданина.

капитальных издержек производства и инфляционных ожиданий наемных работников, способствующих повышению номинальных заработных плат.

На более актуальных статистических данных по США за период с I квартала 2021 г. по I квартал 2023 г. выявлено, что импульсный отклик инфляции положителен в течение только первого квартала под воздействием роста цен на продовольственные товары и энергоносители, а также экзогенного шока, отражением которого является скачок индекса поисковых запросов Google Trends «дефицит». [Blanchard, Bernanke, 2023] связывают это с тем, что краткосрочные и долгосрочные инфляционные ожидания были закорены (устойчивы) в период пандемического кризиса, что нивелировало влияние трех инфляционных шоков на динамику цен. В то же время шок индикатора активности на рынке труда приводит к статистически значимому росту ИПЦ, который сохраняется в течение 16 кварталов. На основе декомпозиции темпов роста ИПЦ выявлено, что за первые два квартала пандемического кризиса основными факторами повышения инфляции являлись рост цен на продовольственные товары и энергоносители. Начиная с I квартала 2020 г. высокую долю инфляции объясняют перебои логистических поставок, что отражает несоответствие между спросом и предложением товаров. О. Бланшар и Б. Бернанке предположили, что сокращение отношения уровня вакансий<sup>10</sup> к уровню безработицы до 1,2 позволит снизить инфляцию до 2,7% в течение 8 кварталов, а если данное отношение станет равным 0,8, то инфляция упадет до 2,0%, что является таргетом Федеральной резервной системы (ФРС).

Таким образом, в исследовании [Blanchard, Bernanke, 2023] выявлено, что инфляция повысилась не только под воздействием состояния рынка труда и производственного сектора, но также из-за роста цен на сырьевые товары и инфляционных ожиданий экономических агентов. В параграфе 2.3 будут проанализированы научные работы, которые посвящены оценке взаимосвязи между инфляцией и показателями финансовой системы. В параграфе 2.4 рассматривается взаимосвязь между темпом роста цен и инфляционными ожиданиями.

---

<sup>10</sup> Уровень вакансий – это отношение числа вакансий к численности занятого населения

### 2.3. Взаимосвязь между инфляцией и показателями финансовой системы

В параграфах 2.1 и 2.2 мы выяснили, что разрывы безработицы и выпуска являются одними из ключевых факторов инфляции. В то же время разрывы безработицы и выпуска зависят от шоков предложения. Одним из показателей шоков предложения могут быть цены на энергоносители. Так, рост цен на энергоносители приводит к повышению производственных издержек, что обуславливает сокращение объема выпуска и уровня занятости. Вторым трансмиссионным каналом влияния цен на энергоносители на инфляцию является рост экспортной выручки, который приводит к повышению инфляции в результате роста агрегированного спроса. Помимо цен на энергоносители к показателям финансовой системы, которые влияют на инфляцию, относятся валютные курсы. В частности, трансмиссионный механизм влияния валютных курсов на инфляцию прослеживается через цены на импортные товары. При прогнозировании инфляции процентные ставки также являются значимым показателем финансового сектора. Это объясняется тем, что процентные ставки отражают ожидания экономических агентов в отношении монетарной политики. Таким образом, на основе вышеуказанных трансмиссионных механизмов мы выделили следующие показатели финансовой системы, которые являются важными при прогнозировании инфляции: 1) цены на сырьевые товары; 2) валютные курсы; 3) процентные ставки. Ниже мы приведем теоретическое обоснование применению показателей финансовой системы при прогнозировании инфляции. Далее перечислим научные работы, в которых применяются показатели финансовой системы при прогнозировании инфляции в развитых и развивающихся странах.

В работе [Estrella, 2005] приводится теоретическое обоснование использования наклона дифференциала процентных ставок в прогнозировании инфляции и валового выпуска. На первом этапе составляется теоретическая модель, которая основана на системе из пяти уравнений, в число которых входят: кривая Филлипса; равновесие на товарном рынке IS (Investment-Saving); монетарное правило; уравнение Фишера; гипотеза ожиданий процентных ставок (2.3.1):

$$\left\{ \begin{array}{l} \pi_t = \pi_{t-1} + a y_{t-1} + \varepsilon_t \\ y_t = b_1 y_{t-1} - b_2 \rho_{t-1} + \eta_t \\ r_t = g_r r_{t-1} + g_y y_t + g_\pi \pi_t + (1 - g_r - g_\pi) \pi^* \\ R_t = \rho_t + \frac{1}{2} (\mathbb{E}_t \pi_{t+1} + \mathbb{E}_t \pi_{t+2}) \\ R_t = \frac{1}{2} (r_t + \mathbb{E}_t r_{t+1}) \end{array} \right., \quad (2.3.1)$$

где  $\pi_t$  – уровень инфляции в период  $t$ ;

$y_t$  – разрыв выпуска;

$\rho_t$  – долгосрочная реальная ставка процента;

$r_t$  – краткосрочная номинальная ставка процента;

$\pi^*$  – целевой уровень инфляции;  $R_t$  – долгосрочная номинальная ставка процента;

$\mathbb{E}_t$  – оператор математического ожидания.

На втором этапе формируется система, в которой определяется отклонение ожидаемых величин выпуска, инфляции, процентных ставок от их целевых значений (2.3.2):

$$CX_{t+1} \equiv \begin{bmatrix} \mathbb{E}_t \pi_{t+1} - \pi^* \\ \mathbb{E}_t \pi_{t+2} - \pi^* \\ \mathbb{E}_t y_{t+1} \\ \mathbb{E}_t r_{t+1} - \pi^* \\ \rho_t \end{bmatrix} = BS_t \equiv \begin{bmatrix} \pi_t - \pi^* \\ y_t \\ r_t - \pi^* \end{bmatrix}. \quad (2.3.2)$$

В результате решения системы уравнений (2.3.2) [Estrella, 2005] аналитически выявил два уравнения, которые теоретически обосновывают применимость оценок наклона кривой доходности в прогнозировании выпуска и инфляции (2.3.3):

$$\begin{cases} \mathbb{E}_t y_{t+1} = \frac{2}{g_y} (R_t - r_t) + \frac{1-g_r}{g_y} (r_t - \pi^*) + \frac{g_\pi}{g_y} (\pi^* - \pi_t - ay_t) \\ \frac{1}{2} (\mathbb{E}_t \pi_{t+1} + \mathbb{E}_t \pi_{t+2}) - \mathbb{E}_t \pi_{t+1} = \frac{a}{g_y} (R_t - r_t) + \frac{a(1-g_r)}{2g_y} (r_t - \pi^*) + \frac{ag_\pi}{2g_y} (\pi^* - \pi_t - ay_t) \end{cases}. \quad (2.3.3)$$

Согласно системе уравнений (2.3.3) взаимосвязь между дифференциалом доходностей государственных облигаций и будущими значениями выпуска и инфляции определяется параметрами монетарного правила из системы (2.3.3):  $g_\pi, g_r, g_y$ . Данный результат позволяет прогнозировать инфляцию на основе таких финансовых показателей, как рыночные ставки процента, доходности государственных и корпоративных облигаций.

[Styrin, Zamulin, 2012] предложили альтернативное теоретическое обоснование применимости финансовых показателей при изучении инфляции. Авторы разработали кривую Филлипа, в которой вместо разрыва безработицы используется отклонение валютного курса от его фундаментального уровня (далее, разрыв валютного курса). Предложенная модель имеет следующее аналитическое представление:

$$\begin{cases} \pi_t = \mathbb{E}_t \pi_{t+1} - \lambda \tilde{q}_t \\ \pi_t = \psi \pi_{t-1} - \lambda \tilde{q}_t \end{cases}, \quad (2.3.4)$$

где  $\pi_t$  – темп роста общего уровня цен;

$E_t$  – оператор математического ожидания;

$\tilde{q} = (1 - \alpha)(x + p_{oil}) - (1 - \alpha)u_T$  – разрыв валютного курса;

$u_T$  – лог-линеаризованное отклонение фактического выпуска от его равновесного уровня;

$p_{oil}$  – лог-линеаризованное отклонение цены на природный ресурс (нефть) от ее равновесной величины;

$x$  – лог-линеаризованное отклонение запасов природных ресурсов от их равновесных объемов;

$\lambda = \frac{(1-\theta)^2}{\theta} \times \frac{(1+k)}{(1-\alpha)+(1+k)}$ ;  $k$  – эластичность предложения труда по Фришу;

$\theta$  – доля фирм, которые не корректируют цены на конечные товары;

$\alpha$  – эластичность выпуска потребительских благ по импортируемым ресурсам.

На статистических данных по 6 странам-экспортерам сырья<sup>11</sup> за период со II квартала 1972 г. по IV квартал 2007 г. [Styrin, Zamulin, 2012] эмпирически обосновали применимость предложенной кривой Филлипса при оценке инфляции на основе разрыва валютного курса.

Помимо валютного курса в научной литературе применяются и другие финансовые показатели при прогнозировании инфляции. В работе [Stock, Watson, 2003] оценили 211 моделей, в которых учитываются следующие финансовые показатели: валютные курсы, цены на сырьевые товары, рыночные процентные ставки, цены на акции. На статистических данных по 7 развитым странам<sup>12</sup> Организации экономического сотрудничества и развития (далее, ОЭСР) за период с 1959 г. по 1999 г. получено, что только в 6% случаев учет финансовых показателей повышает точность моделей по сравнению с авторегрессией. Это может объясняться тем, что в моделях прогнозирования инфляции наблюдается нестабильность параметров. Однако комбинирование прогнозов моделей позволяет точнее прогнозировать инфляцию по сравнению с авторегрессией.

В отличие от [Stock, Watson, 2003] в работе [Forni et al., 2003] отмечается, что учет финансовых показателей повышает точность прогнозирования инфляции на горизонте в 1

<sup>11</sup> В число этих стран входят Австралия, Канада, Новая Зеландия, Норвегия, Россия, Южная Африка.

<sup>12</sup> В число этих стран входят Великобритания, Германия, Италия, Канада, США, Франция, Япония.

и 3 месяца, что подтверждается на статистических данных по 6 странам Еврозоны<sup>13</sup> за период с февраля 1987 г. по март 2001 г.

Помимо развитых стран, в научной литературе также применяются финансовые показатели при прогнозировании инфляции в развивающихся странах. [Третьяков, Фокин, 2021] при прогнозе инфляции в России учитывали следующие финансовые показатели: 1) валютный курс руб./долл. США для оценки эффекта переноса валютного курса в инфляцию; 2) цена на нефть для учета притока капитала (роста экспортной выручки), который повышает агрегированный спрос. Получено, что модели Mixed Data Sampling (далее, MIDAS) с учетом финансовых показателей предоставляют более точные прогнозы инфляции по сравнению с моделями Autoregression Integrative Moving Average (далее, ARIMA) за период с января 2018 г. по ноябрь 2019 г.

В работе [Картаев, Беседовская, 2023] оценивается влияние показателей развития финансового сектора на эффективность режима инфляционного таргетирования, которая определяется как абсолютное и относительное отклонение инфляции от ее целевого значения. На первом этапе авторы агрегируют показатели развития финансового сектора методом главных компонент. На втором этапе главные компоненты используются как объясняющие переменные в моделях с фиксированными эффектами. На примере 36 развитых и развивающихся стран за 1991-2015 гг. авторы получили следующие результаты: для развивающихся стран наиболее значимым фактором эффективности инфляционного таргетирования является стабильность финансовой системы, а для достижения целевой инфляции в развитых странах важными факторами являются эффективность и открытость финансовой системы.

[Трунин, Пономарев, 2014] перечисляют три канала влияния валютного курса на цены. Во-первых, прямой канал выражается в том, что изменение валютного курса влияет на цены импортных товаров, которые учитываются в ИПЦ. Во-вторых, косвенный канал связан с тем, что ослабление курса национальной валюты приводит к замещению импортной продукции товарами внутренних производителей. Объясняется это тем, что при ослаблении курса национальной валюты повышаются цены на импортные товары по сравнению с ценами на продукцию внутренних фирм. Третий канал подразумевает следующий трансмиссионный механизм: ослабление курса национальной валюты → повышение объемов иностранных инвестиций, так как зарубежные фирмы увеличивают локализацию производства → повышение спроса на труд и заработных плат внутри страны

---

<sup>13</sup> Использовались данные по Бельгии, Германии, Испании, Италии, Нидерландам и Франции.

→ повышение инфляции. При оценке векторной модели коррекции ошибок на статистических данных по России за период с января 2000 г. по август 2013 г. авторы выявили следующие закономерности. Во-первых, ослабление номинального валютного курса рубля к долл. приводит к росту индекса цен на потребительские (базовые, продовольственные и непродовольственные) товары, а также цен производителей. Выявлено, что эффект переноса валютного курса в цены меняется в диапазоне от 5,02% до 94,2% и сохраняется в течение 12 месяцев. Во-вторых, рост цен из-за ослабления курса рубля выше, чем снижение цен из-за укрепления номинального эффективного курса, валютного курса рубля к долл., к евро.

Стоит отметить, что мировая экономика значимо влияет на перечисленные выше финансовые факторы инфляции, в том числе на: цены сырьевых товаров, валютные курсы, доходности облигаций, процентные ставки. Следовательно, повышается влияние глобальной экономики на инфляцию отдельных стран. [Абрамов и др., 2022] приводят три канала, через которые глобальная экономика влияет на инфляцию в малой экономике. Во-первых, рост мировых цен на торгуемые товары<sup>14</sup> приводит к повышению инфляции в малой экономике из-за роста цен импортируемых и неторгуемых товаров<sup>15</sup>. Во-вторых, рост мирового спроса на торгуемые товары приводит к повышению инфляции в малой экономике из-за роста в ней агрегированного спроса. В-третьих, рост цен на сырьевые товары повышает экспортную выручку, что приводит к повышению инфляции в малой открытой экономике из-за роста агрегированного спроса. На статистических данных по России за период с 2003 г. по 2018 г. получено, что 30% дисперсии роста ИПЦ приходится на глобальные факторы.

[Nagy, Tengey, 2018] считают, что глобальная экономика влияет на инфляцию в малой экономике через ее интеграцию в международную торговлю и мировые цепочки добавленной стоимости. Более интенсивная интеграция малой экономики в глобальную приводит к однонаправленной динамике производственных затрат в развитых и развивающихся странах. Авторы применили метод главных компонент для того, чтобы оценить три ненаблюдаемых фактора инфляции в Венгрии: 1) глобальный фактор, который отражает мировые цены на сырьевые товары и деловую активность стран Европейского союза (далее ЕС); 2) региональный фактор, который отражает макроэкономическую

---

<sup>14</sup> К торгуемым относятся товары и услуги, которые производятся и экспортируются внутренними и зарубежными фирмами: машины, компьютеры, фармацевтические товары [Blanchard, 2021].

<sup>15</sup> Неторгуемыми являются товары и услуги, которые производятся внутренними фирмами и поставляются на внутренний рынок: недвижимость, медицинские услуги [Blanchard, 2021].

конъюнктуру стран Вышеградской группы<sup>16</sup>; 3) внутривострановые факторы венгерской экономики. На статистических данных за период с 2003 г. по 2017 г. получено, что 72,6% инфляции в Венгрии объясняются глобальными и региональными, а 27,4% – внутривострановыми факторами. В кривой Филлипса коэффициент при разрыве выпуска ЕС превышает коэффициент при разрыве выпуска Венгрии, что указывает на больший вклад мировых факторов в инфляцию по сравнению с внутренними факторами ценовой стабильности.

[Картаев, Медведев, 2020] отмечают, что цены на нефть влияют на инфляцию через два канала. В рамках прямого канала цены на нефть влияют на издержки производства. В рамках косвенного канала цены на нефть влияют на внутренние цены через валютный курс. Авторы также оценивают влияние денежно-кредитной политики на характер взаимосвязи между инфляцией и ценами на нефть. На статистических данных по 38 странам за период 1970-2017 гг. получены следующие результаты. Во-первых, переход к режиму инфляционного таргетирования замедляет темп роста цен. Во-вторых, за период 2000-2008 гг. рост цен на нефть приводит к повышению инфляции. В-третьих, за период 2000-2008 гг. получен отрицательный коэффициент при переменной взаимодействия между ценами на нефть и индикаторной функцией перехода к режиму таргетирования инфляции. Это означает, что при повышении цен на нефть режим инфляционного таргетирования способствует замедлению темпов роста цен. Таким образом, результаты исследования [Картаев, Медведев, 2020] подчеркивают важность учета денежно-кредитной политики при оценке взаимосвязи между инфляцией и показателями глобальной экономики. В связи с этим рассмотрим трансмиссионные каналы и эмпирические оценки влияния экономической политики на инфляцию.

Среди научной литературы по эмпирической проверке влияния денежно-кредитной политики на инфляцию отметим работу [Картаев, 2016]. Автор отмечает, что стремление к достижению целевых монетарных показателей приводит к замедлению инфляции за счет решения проблемы временной несогласованности. Новизна работы [Картаев, 2016] заключается в том, что в моделях на панельных учитываются одновременно три режима денежно-кредитной политики: таргетирования инфляции, валютного курса, денежной массы. На статистических данных по 188 развитым и развивающимся странам за период с 1999 г. по 2014 г. получены следующие результаты. Во-первых, для развитых стран не выявлено статистически значимого влияния монетарных якорей на инфляцию. Во-вторых,

---

<sup>16</sup> Венгрия, Польша, Словакия, Чехия.

режим таргетирования инфляции и валютного курса позволяют снизить темп роста цен в развивающихся странах.

Среди российских исследований [Поршаков, Пономаренко, 2008] также изучают взаимосвязь между инфляцией и монетарными показателями. Авторы отмечают, что инфляционные процессы могут меняться за счет двух составляющих: 1) краткосрочной компоненты, которая определяется уровнем занятости; 2) долгосрочной компоненты, которая зависит от предложения денег. В силу этого авторы разделяют две компоненты при оценке инфляционных процессов в России, выделяя: 1) инфляцию спроса, которая определяется как отклонение денежного предложения от его естественного объема (далее, монетарный разрыв); 2) инфляцию предложения, которая связана с предельными издержками производителей. На статистических данных по России за период с января 1999 г. по сентябрь 2007 г. получено, что рост разрыва денежного предложения на 1 п. п. приводит к повышению инфляции на 0,02 п. п. При этом данная эластичность сохраняет устойчивость на протяжении 5 лет: с января 2002 г. по июль 2007 г. Во-вторых, инфляция повышалась в те периоды, когда наблюдалось избыточное предложение денег, а именно превышение фактической денежной массы по отношению к ее естественному объему. В-третьих, итоговая эластичность темпов роста индекса потребительских цен по монетарному разрыву составляет 0,055. Таким образом, 20% повышения потребительской инфляции в России приходились на монетарные факторы.

В зарубежных исследованиях также обнаружены свидетельства того, что монетарные факторы приводят к повышению инфляции. [Lucas, 1996] на примере 110 стран за 30-летний период 1960-1990 гг. выявил, что при ускорении темпов роста денежной массы наблюдается повышение инфляции.

Однако К. Симс отмечает, что объем денежного предложения не может являться единственным показателем денежно-кредитной политики [Sims, 2012]. В исторической перспективе кейнсианский подход к моделированию экономической политики предполагал необходимость составления большой системы уравнений, так как экономика рассматривается как сложная система. В то же время монетаристский подход предполагает, что достаточно сосредоточиться на рассмотрении исторического контекста и нескольких наиболее важных экономических показателей, таких как денежное предложение и цены. При этом считается, что влияние денежного предложения на доходы имеет причинно-следственный характер, то есть монетарные показатели являются экзогенными переменными. Однако К. Симс отмечает, что предпосылка об экзогенности

макроэкономических показателей не позволяет формировать их точные прогнозы и вырабатывать оценки последствий экономической политики. Процентные ставки и денежное предложение зависят не только от показателей экономической политики. В частности, рыночные ставки процента будут зависеть от инфляции и реальной доходности инвестиций.

Как было выявлено в работе [Картаев, Медведев, 2020] режим инфляционного таргетирования влияет на характер взаимосвязи между инфляцией и ценами на нефть. В то же время в научных исследованиях подчеркивается, что механизм регулирования валютного курса также влияет на инфляционные процессы. Так [Geerolf, 2020] отмечает, что предпосылки кривой Филлипса соблюдались в Великобритании и США при Бреттон-Вудской системе, когда страны придерживались режима фиксированного валютного курса. При оценке кривой Филлипса на примере США за период с 1971 г. по 2018 г. выявлен статистически значимый отрицательный коэффициент при уровне безработицы для тех отраслей, продукция которых ориентирована на внутреннее потребление, то есть представляет собой неторгуемые товары. Предпосылки кривой Филлипса не соблюдаются в тех отраслях, которые ориентированы на экспорт, то есть производят торгуемые, экспортируемые товары. Объясняется это тем, что уровень занятости в экспортно-ориентированных отраслях определяется не только внутренним, но и мировым спросом, что снижает эластичность инфляции по уровню занятости в малой открытой экономике.

Р. Манделл полагает, что кризис 1930 гг. в США был вызван тем, что ФРС придерживалась жесткой денежно-кредитной политики при снижении цен на золото. В 1944 г. Бреттон-Вудское соглашение позволило США фиксировать цены на золото, а остальным странам фиксировать курс их национальной валюты к доллару. Таким образом, курс доллара приобрел роль мирового уровня цен. В период Второй мировой войны импорт золота в США стерилизовалось интервенциями ФРС, что позволяло стране одновременно сохранять дефицит бюджета, придерживаться золотовалютного режима и контролировать уровень цен. Р. Манделл подчеркивает, что режим фиксированного валютного курса может эффективно функционировать только в том случае, когда все страны-участницы придут к согласию относительно установления единого уровня инфляции. С 1973 г. страны отошли от режима фиксирования курса национальных валют к доллару. Этот переход позволил предложению денег быть более гибким, что способствовало повышению инфляции в мировой экономике. В 1970 гг. рост общего уровня цен сопровождался повышением цен на сырьевые товары. Это имело место в отношении как энергоносителей (нефти), так и драгоценных металлов (золота, серебра). На смену краткосрочной экономической политике

Дж. М. Кейнса приходит доктрина экономики предложения, в рамках которой предлагался следующий ряд мер: стабилизация цен через монетарное правило; стимулирующая фискальная политика в форме снижения налоговых ставок для роста занятости и выпуска. Ужесточение денежно-кредитной политики ФРС под руководством П. Волкера позволило снизить инфляцию в США. Р. Манделл полагал, что XXI век будет характеризоваться конвергенцией в инфляции, сохранением три-полярной системы валютных курсов между долларом, евро и йеной. Одним из выводов по монетарной политике XX века является то, что режим плавающего валютного курса необязательно является негативным фактором для экономики [Mundell, 2000].

Данная точка зрения согласуется с современными научными исследованиями. В частности, [Картаев, Лунева, 2018] подчеркивают, что достижению целей по инфляции может способствовать сглаживание колебаний валютного курса в те периоды, когда его волатильность связана с нефундаментальными факторами. Объясняется это тем, что волатильность курса национальной валюты повышает инфляционные ожидания и усиливает эффект переноса валютного курса в цены. Авторы отмечают, что классификация Международного валютного фонда (МВФ) по чистому и гибриднему инфляционному таргетированию может не соответствовать фактической денежно-кредитной политике. В силу чего авторы классифицировали страны с точки зрения приверженности режимам свободного и управляемого валютного курса с помощью метода k-средних, используя статистическую информации по волатильности курса национальной валюты к долл. США и валютных интервенций. На статистических данных по 32 странам за период 2000-2016 гг. получено, что режим гибридного инфляционного таргетирования повышает вероятность достижения цели по инфляции.

Также в научной литературе отмечается, что уровень инфляции изменяется не только под влиянием монетарных факторов, но и как результат воздействия инструментов бюджетно-налоговой политики [Sargent, Wallace, 1981; Cochrane, 2001; Sims, 2010]. Так [Cochrane, 2023] полагает, что актуальность фискальной теории уровня цен повышается в современный период, когда большинство центральных банков регулируют процентные ставки, но не денежные агрегаты. Также онлайн платежи приводят к тому, что цены и заработные платы могут стремительно меняться, что противоречит экономическим воззрениям, господствовавшим в недавнем прошлом, в соответствии с которыми постулировалась жесткость номинальных показателей.

Согласно фискальной теории уровня цен ценность денежных средств определяется уровнем их значимости для пополнения государственного бюджета [Cochrane, 2023, С. 5]:

$$B_0 = P_1 s_1 = P_1 \tau y_1, \quad (2.3.5)$$

где  $B_0$  – объем государственных облигаций в период 0;

$P_1$  – уровень цен в период 1;  $y_1$  – номинальный доход;

$\tau$  – ставка налогообложения;  $P_1 s_1$  – бюджетный профицит;

$s_1$  – объем реальных налоговых отчислений в государственный бюджет. Отрицательное значение данного показателя ( $s_1 < 0$ ) отражает бюджетный дефицит.

Дж. Кохрейн полагает, что будущий уровень цен подстраивается под текущий объем налоговых отчислений и государственных облигаций. В то же время текущий уровень цен подстраивается таким образом, чтобы приравнять реальный объем государственного долга к текущей стоимости реальных будущих налоговых отчислений за вычетом трансфертов. Инфляция возникает, когда объем денежной массы превышает размер налоговых отчислений. Также инфляция ускоряется в тех случаях, когда будущая эмиссия государственных облигаций меньше объема текущего государственного долга. Таким образом, государственный долг обуславливает инфляцию. Это предположение отличается от воззрений монетаристов, согласно которым инфляция возникает из-за предложения денег, которое превышает спрос на деньги для осуществления трансакций, как средство сохранения стоимости (для осуществления сбережений), а также по мотиву предпочтения ликвидности.

Дж. Кохрейн предлагает следующее аналитическое представление взаимосвязи между инфляцией и бюджетными дефицитами [Cochrane, 2023, С. 67]:

$$\sum_{j=0}^{\infty} w^j \Delta \mathbb{E}_{t+1} \pi_{t+1+j} = - \sum_{j=0}^{\infty} p^j \Delta \mathbb{E}_{t+1} \tilde{s}_{t+1+j}, \quad (2.3.6)$$

где  $\mathbb{E}_{t+1}$  – оператор математического ожидания;

$\Delta$  – оператор разности первого порядка;  $j$  – индекс периода;

$w^j = \frac{B_t^{t+j}}{B_t}$  – темп роста эмиссии государственных облигаций за период  $t$  и  $t + j$ ;

$p = e^{r-g}$  – экспоненциальная функция разности между реальной доходностью государственных облигаций  $r$  и темпом роста ВВП  $g$ ;

$\tilde{s}_{t+1+j}$  – логарифмическое отклонение бюджетного профицита от его равновесного уровня;

$\pi_{t+1+j}$  – уровень инфляции в период  $t + 1 + j$ .

Шок фискальной политики в форме роста бюджетного дефицита приводит к повышению инфляции, которое снижает стоимость государственных облигаций при их погашении. Дж. Кохрейн отмечает, что периоды высокой инфляции ассоциируются с дефицитом государственного бюджета. На основе оценок векторных авторегрессий на статистических данных по США за период 1947-2018 гг. выявлено, что 1,5-процентный фискальный шок приводит к повышению инфляции на 1%.

В российских исследованиях также изучается взаимосвязь между бюджетно-налоговой политикой и инфляцией. [Мясников и др., 2023] полагают, что трансмиссионный механизм взаимосвязи между фискальной политикой и темпами роста цен заключается в том, что бюджетный дефицит приводит к росту фактических и ожидаемых значений денежных агрегатов, что способствует повышению инфляции. Авторы отмечают, что для оценки бюджетной политики необходимо корректировать показатели первичного баланса в зависимости от фазы делового цикла. Объясняется это тем, что бюджетный дефицит может меняться не только из-за фискальной политики, но и из-за макроэкономической конъюнктуры. В силу чего в качестве показателя бюджетной политики выбирается бюджетный импульс, который скорректирован на уровень цен на нефть. При этом бюджетный импульс рассчитывается согласно формуле (2.3.7) [Мясников и др., 2023, С. 11-12]:

$$FI = -\Delta(CAB) = -\Delta(R_{ca} - G) = -\Delta\left(R\left(\frac{Y_p}{Y}\right)^e - G\right), \quad (2.3.7)$$

где  $\Delta$  – оператор первой разности;

$CAB = (R_{ca} - G)$  – циклически скорректированный первичный баланс государственного бюджета;

$R_{ca} = R\left(\frac{Y_p}{Y}\right)^e$  – циклически скорректированные доходы государственного бюджета;

$R$  – доходы государственного бюджета;

$Y$  – фактический объем валового выпуска;

$Y_p$  – потенциальный уровень валового выпуска;

$e$  – эластичность государственных доходов;

$G$  – расходы государственного бюджета.

Следовательно, положительный бюджетный импульс означает увеличение бюджетного дефицита. Согласно оценкам моделей на панельных данных по 77 регионам России за период 2010-2011 гг. получены следующие результаты. Во-первых, с увеличением бюджетного дефицита наблюдается повышение общего уровня цен во всех 77 регионах России. Во-вторых, в российских регионах с высоким уровнем валового регионального продукта (ВРП) на душу населения рост бюджетного дефицита ассоциируется со снижением инфляции. В-третьих, в регионах со средним и низким уровнем ВРП на душу населения увеличение бюджетного дефицита приводит к повышению инфляции.

В работе [Андреев, 2022] отмечается, что бюджетное правило влияет не только на выпуск, но и на уровень цен, а также на курс национальной валюты. Объясняется это тем, что при действии бюджетного правила стабилизируются расходы государственного бюджета, что также сглаживает колебания агрегированного спроса. Стабилизация государственных расходов происходит при установлении лимита на дефицит бюджета и государственного долга. В то же время бюджетное правило нивелирует эффект переноса валютного курса в цены через снижение волатильности курса национальной валюты при ухудшении условий торговли. Помимо сглаживания расходов бюджетное правило предполагает распределение части государственных доходов в суверенные фонды при улучшении условий торговли. При калибровке динамической стохастической модели общего равновесия получены следующие результаты. Во-первых, 10-процентный шок условий торговли приводит к укреплению курса национальной валюты. При действии бюджетного правила, диктующего необходимость сбережения нефтегазовых доходов, наблюдается снижение инфляции из-за сокращения государственных расходов и снижения цен на импортные товары вследствие укрепления национальной валюты. Инфляция повышается при отсутствии сглаживания бюджетных доходов от продажи сырьевых ресурсов в те периоды, когда улучшаются условия торговли. Наибольшее замедление инфляции обеспечивается при действии бюджетного правила, которое предполагает сбережение нефтегазовых доходов в иностранных активах и осуществление займов на внутреннем финансовом рынке. Объясняется это тем, что внешний фонд финансовых активов сглаживает волатильность валютного курса, а займы на внутреннем финансовом рынке сглаживают колебания государственных расходов.

[Sargent, Wallace, 1981] приводят следующие уравнения, которые определяют взаимосвязь уровня цен с показателями денежно-кредитной и бюджетно-налоговой политики [Sargent, Wallace, 1981, С. 5]:

$$\left\{ \begin{array}{l} b_T^\theta = \phi_{t,1} b_1 + \sum_{s=2}^t \phi_{t,s} \left( \frac{D_s}{N_s} \right) - \left( \frac{h\theta}{1+\theta} \right) \sum_{s=2}^t \phi_{t,s} \\ 1 - \left( \frac{1}{1+n} \right) \left( \frac{p_{t-1}}{p_t} \right) = \frac{D_t}{N_t} + \left( \frac{R_{t-1}-n}{1+n} \right) \frac{b_T^\theta}{h} \\ p_t = \frac{2}{\gamma_1} \sum_{j=0}^{\infty} \left( \frac{\gamma_2}{\gamma_1} \right)^j \times \frac{H_{t+j}}{N_{t+j}} \end{array} \right. , \quad (2.3.8)$$

где  $p_t$  – уровень цен в период  $t$ ;  $h > 0, \gamma_1 > 0, \gamma_2 > 0$ ;

$H_t$  – объем денежной базы как индикатор денежно-кредитной политики;

$N_t$  – численность населения, растущего темпом, равным  $n$ ;

$D_t$  – реальный бюджетный дефицит как индикатор бюджетно-налоговой политики;

$R_t$  – реальная доходность государственных облигаций;

$b_t = \frac{B_t}{N_t}$  – объем государственных облигаций на душу населения;

$\theta = \left( \frac{H_t}{H_{t-1}} - 1 \right)$  – темп прироста денежной базы;

$b_T^\theta$  – объем государственных облигаций на душу населения с учетом темпа прироста денежной базы.

Согласно первому уравнению системы (2.3.8), ужесточение денежно-кредитной политики в форме снижения темпов роста денежной базы (то есть, снижение  $\theta$ ) приводит к увеличению объема государственного долга (то есть,  $b_T^\theta$ ), что подчеркивает необходимость координации денежно-кредитной и бюджетно-налоговой политики при регулировании инфляции. Второе уравнение системы (2.3.8) показывает, что увеличение реального государственного долга (то есть, рост  $b_T^\theta$ ) приводит к повышению инфляции, подчеркивая, тем самым, важность учета результативности бюджетно-налоговой политики для достижения ценовой стабильности. Третье уравнение системы (2.3.8) отражает зависимость текущего уровня цен от текущего и будущего объема денежной базы. Таким образом, ценовая динамика зависит от ожиданий экономических агентов относительно будущей денежно-кредитной политики. В связи с этим в следующем параграфе 2.4 будут рассмотрены исследования, в которых подчеркивается важность учета инфляционных ожиданий при изучении динамики цен.

#### 2.4. Учет инфляционных ожиданий при изучении ценовой динамики

В параграфе 2.3 мы выяснили, что важными факторами инфляции являются показатели финансовой системы: процентные ставки, цены на сырьевые товары, валютные

курсы. В то же время изменение финансовых показателей определяется ожиданиями экономических агентов относительно деловых циклов, денежно-кредитной и бюджетно-налоговой политики, что также было отмечено в параграфе 2.3. Таким образом, ожидания экономических агентов также важны при прогнозировании инфляции. Данное предположение позволило прояснить причины одновременного повышения инфляции и безработицы (далее, стагфляции) в 1970-х гг. из-за роста цен на нефть, которое противоречило предпосылкам кривой Филлипса. Объяснение причин стагфляции были предложены М. Фридманом [Friedman, 1968] и Э. Фелпсом [Phelps, 1968]. Они отмечали, что причиной стагфляции являлся рост ожиданий экономических агентов относительно инфляции (далее, инфляционные ожидания). Объясняется это тем, что с ростом инфляционных ожиданий меняется расположение кривой Филлипса, происходит ее сдвиг в направлении повышения инфляции и роста уровня безработицы (Рисунок 2.4.1). Вертикальный наклон кривой Филлипса в долгосрочной перспективе объясняется тем, что с течением времени инфляционные ожидания будут корректироваться таким образом, что ожидаемая и фактическая инфляции оказываются равны [Abel et al., 2014, С. 462].

М. Фридман отмечал, что предпосылки кривой Филлипса объясняются влиянием неожиданного изменения номинального спроса на рынках товаров и труда [Friedman, 1977]. Если экономические агенты ожидают 20-процентного роста цен, то эти прогнозы будут закладываться в будущие трудовые контракты, а реальная заработная плата будет корректироваться под 20-процентный рост цен. При росте номинальной заработной платы повышается предложение труда, так как наемные работники воспринимают рост номинальных доходов как рост их реальной покупательной способности. На примере 7 развитых стран<sup>17</sup> было выявлено, что предпосылки кривой Филлипса перестают соблюдаться с течением времени. Рост цен на нефть напрямую повлиял на производственный процесс и привел к росту уровня безработицы.

По мнению М. Фридмана, компромисс между уровнем инфляции и безработицы достигается не за счет роста цен, а из-за неожиданной инфляции. При этом влияние неожиданной инфляции на уровень безработицы имеет временный характер продолжительностью от 2 до 5 лет, после чего рынок труда адаптируется к новому уровню цен. Принимая во внимание значимость ожиданий, М. Фридман подчеркивал, что эффективное функционирование экономической системы будет обеспечено, если работники и работодатели, производители и потребители будут уверены в стабильности темпа роста цен [Friedman, 1968].

---

<sup>17</sup> В их число входят Франция, Германия, Италия, Япония, Швеция, Великобритания и США.

Р. Лукас также отмечал, что ожидаемая стимулирующая денежно-кредитная политика не влияет на занятость и производство, а соответственно, и на инфляцию. В свою очередь, неожиданная стимулирующая денежно-кредитная политика приводит к росту объемов производства. Объясняется это тем, что при проведении экономической политики необходимо учитывать ожидания экономических агентов [Lucas, 1976]. Мнение [Friedman, 1968; Lucas, 1976] подтверждается [Картаев, Леденева, 2021]: через уменьшение асимметрии информации, управление инфляционными ожиданиями экономических агентов и повышение прозрачности проведения денежно-кредитной политики увеличивается ее результативность трансмиссионного механизма, который приводится ею в действие. На статистических данных по 32 странам за 1998-2016 гг. выявлено, что более прозрачная политика центрального банка повышает вероятность достижения целевых значений по инфляции.

Кривая Филлипа для заработных плат с учетом инфляционных ожиданий описывается дифференциальным уравнением [Phelps, 1968]:

$$\frac{\dot{w}}{w} = f(u, z) + \frac{w^e}{w}, \quad (2.4.1)$$

где  $w^e$  – ожидаемая ставка заработной платы;

$u$  – фактический уровень безработицы;

$f(u, z) = \Delta^* = \frac{w^* - w}{w}$  – процентное отклонение предпочтительной для работодателей ставки заработной платы,  $w^*$ , от их фактических трудовых затрат  $w$ ;

$z$  – избыточный спрос на труд.




Рисунок 2.4.1 – Изменение расположения кривой Филлипа при разных уровнях инфляционных ожиданий. Источник: составлено автором

Наряду с М. Фридманом и Э. Фелпсом, сторонниками введения ожиданий экономических агентов в кривую Филлипса являлись Т. Саргент и его соавторы [Sargent et al., 2006]. Кривая Филлипса в их трактовке имеет следующее аналитическое представление:

$$\begin{cases} \pi_t = \pi^* - \lambda(u^{**} - u^*) \times [(1 + \delta\tau_1)\theta_0 + \delta\theta_1] \\ u^{**} - u^* = \theta_0(\pi_t - \mathbb{E}_{t-1}\pi_t) + \theta_1(\pi_{t-1} - \mathbb{E}_{t-2}\pi_{t-1}) + \tau_1(u_{t-1} - u^{**}) + \sigma_1 w_{1t}, \end{cases} \quad (2.4.2)$$

где  $\pi^*$  – целевое значение инфляции;  $\mathbb{E}_t$  – оператор математического ожидания;

$u^{**}$  – естественный уровень безработицы;  $u^*$  – целевой уровень безработицы;

$w_{1t} \sim \mathcal{N}(0,1)$  – случайные ошибки, которые имеют стандартное распределение

Гаусса.

На статистических данных по США за период 1960-2005 гг. модель [Sargent et al., 2006] по сравнению с байесовской векторной авторегрессией точнее прогнозирует инфляцию на горизонте 1, 12, 48 месяцев.

Новая кейнсианская кривая Филлипса включает в себя, помимо уровня безработицы, прогнозы предельных издержек и рациональные инфляционные ожидания [Mavroedis et al., 2014]. Рациональными инфляционными ожиданиями являются точные прогнозы инфляции на  $h$  периодов вперед  $\pi_{t+h}$  с учетом информации текущего периода  $t$ ,  $\mathbb{E}_t(\pi_{t+h})$ . При адаптивных инфляционных ожиданиях темп роста цен  $\pi_t$  определяется его лаговыми значениями порядка  $p$ ,  $\pi_{t-p}$ , и показателями предельных издержек. Пошагово выведем аналитическое представление новой кейнсианской кривой Филлипса.

Шаг 1. Определим предпосылки модели: (A1) фирмы функционируют в условиях монополистической конкуренции и производят товары с эластичностью спроса по цене  $\varepsilon > 1$ ; (A2) в каждый момент времени  $t$  часть фирм (их доля равна  $\theta$ ) не корректируют цены, так как сталкиваются с издержками изменения цен на производимые товары и услуги; (A3) в каждый момент времени  $t$  часть фирм (их доля равна  $(1 - \theta)$ ) устанавливают оптимальные цены на производимые товары и услуги; (A4) каждая фирма (с номером  $i \in [0,1]$ ) имеет рациональные ожидания, которые идентичны прогнозам других фирм  $E_{i,t} \equiv E_t$ ; (A5) предельные издержки прямо пропорциональны (1) отношению номинальных издержек труда к номинальному выпуску, (2) разрыву выпуска.

Шаг 2. С учетом предпосылок (A1)-(A3), общий уровень цен меняется согласно уравнению (2.4.3):

$$p_t = \theta p_{t-1} + (1 - \theta) \int_0^1 p_{i,t}^* di, \quad (2.4.3)$$

где  $p_t$  – общий уровень цен;  $\theta$  – параметр ценовой жесткости;

$p_{i,t}^* = (1 - \theta\beta) \sum_{j=0}^{\infty} (\theta\beta)^j E_{i,t}(mc_{i,t+j}^n)$  – оптимальный уровень цен на товары и услуги, которые производит фирма  $i$ ;  $\beta$  – фактор дисконтирования;

$mc_{i,t+j}^n = mc_{t+j}^n + \frac{\alpha\varepsilon}{1-\alpha} (p_{i,t}^* - p_{t+j})$  – номинальные предельные издержки периода  $t + j$  фирмы с номером  $i$ , которая в период  $t$  корректировала цены на производимые товары и услуги;

$\alpha$  – эластичность выпуска по капиталу в производственной функции Кобба-Дугласа;  
 $mc_{t+j}^n$  – общий уровень номинальных предельных издержек в период  $t + j$ .

Шаг 3. С учетом номинальных предельных издержек  $mc_{i,t+j}^n$  и оптимального уровня цен  $p_{i,t}^*$ , уравнение (2.4.3) приобретает вид (2.4.4):

$$p_{i,t}^* - p_{t-1} = (1 - \theta\beta) \sum_{j=0}^{\infty} (\theta\beta)^j [kE_{i,t}(mc_{t+j}) + E_{i,t}(\pi_{t+j})], \quad (2.4.4)$$

где  $k = \frac{1-\alpha}{1-\alpha+\alpha\varepsilon}$ ;  $mc_{t+j} = (mc_{t+j}^n - p_t)$  – общий уровень реальных предельных издержек в период  $t + j$ ;

$\pi_t = (p_t - p_{t-1})$  – уровень инфляции в период  $t$ .

Шаг 4. Подстановка оптимального уровня цен  $p_{i,t}^*$  из уравнения (2.4.3) в уравнение (2.4.4) позволяет вывести аналитическое представление уровня инфляции в период  $t$ :

$$\pi_t = (1 - \theta\beta) \sum_{j=0}^{\infty} (\theta\beta)^j [k\hat{E}_t(mc_{t+j}) + \hat{E}_t(\pi_{t+j})], \quad (2.4.5)$$

где  $\hat{E}_t = \int_0^1 E_{i,t} di$  – математическое ожидание, усредненное по всем фирмам.

Шаг 5. С учетом предпосылки (A4), математическое ожидание уровня инфляции (2.4.5) в следующий период  $t + 1$  имеет вид (2.4.6):

$$E_t(\pi_{t+1}) = (1 - \theta\beta) \sum_{j=0}^{\infty} (\theta\beta)^j [kE_t(mc_{t+j}) + E_t(\pi_{t+j})], \quad (2.4.6)$$

Шаг 6. Разность фактического уровня инфляции (2.4.5) и инфляционных ожиданий (2.4.6) составит:

$$\pi_t = \beta E_t(\pi_{t+1}) + \frac{(1-\theta)(1-\theta\beta)}{\theta} \cdot k \cdot mc_t, \quad (2.4.7)$$

Шаг 7. С учетом предпосылки (A5) и ошибок регрессий, уравнение (2.4.7) приобретает вид (2.4.8):

$$\pi_t = \beta E_t(\pi_{t+1}) + \lambda \cdot x_t + u_t, \quad (2.4.8)$$

где  $x_t$  – показатель реальных предельных издержек;  $u_t$  – ошибки регрессии.

Гибридная кривая Филлипса включает адаптивные и рациональные инфляционные ожидания (2.4.9):

$$\gamma(L)\pi_t = \gamma_f \mathbb{E}_t(\pi_{t+1}) + \lambda \cdot x_t + u_t, \quad (2.4.9)$$

где  $\gamma(L) = (1 - \gamma_1 L^1 - \gamma_2 L^2 - \dots - \gamma_l L^l)$  – полином лага.

При  $\gamma(L) = 0$  получается кривая Филлипса с рациональными ожиданиями, а при  $\gamma_f = 0$  – кривая Филлипса с адаптивными ожиданиями.

Взаимосвязь между уровнем безработицы, объемом выпуска, заработными платами, общим уровнем цен и инфляционными ожиданиями определим следующим аналитическим представлением кривой Филлипса [Blanchard, 2021].

Шаг 1. Номинальная заработная плата определяется уравнением:

$$W_t = P_t^e F(u_t, z_t) = P_t^e (1 - \alpha u_t + z_t), \quad (2.4.10)$$

где  $W_t$  – номинальная заработная плата в период  $t$ ;

$P_t^e$  – ожидаемый уровень цен;  $u_t$  – уровень безработицы;

$z_t$  – показатели функционирования рынка труда: пособия по безработице, переговорная сила профсоюзов.

Шаг 2. Предположим, что в краткосрочном периоде выпуск определяется производственной функцией  $Y_t = N_t$ , где  $Y_t$  – объем выпуска;  $N_t$  – численность работников. С учетом производственной функции  $Y_t = N_t$  цена единицы товара  $P_t$  равняется предельным издержкам  $W_t$ . Так как фирмы осуществляют ценообразование на товары в виде надбавки к предельным издержкам, общий уровень цен составит (2.4.11):

$$P_t = (1 + m_t)W_t = (1 + m_t)P_t^e (1 - \alpha u_t + z_t), \quad (2.4.11)$$

где  $m$  – параметр ценообразования по принципу «издержки+».

Переходя от уровня цен (2.4.11) к темпам их роста, получим кривую Филлипса с учетом уровня безработицы (2.4.12):

$$\pi_t = \pi_t^e + (m_t + z_t) - \alpha u_t, \quad (2.4.12)$$

где  $\pi_t \triangleq \frac{P_t - P_{t-1}}{P_{t-1}}$  – инфляция в период  $t$ ;  $\pi_t^e \triangleq \frac{P_t^e - P_{t-1}}{P_{t-1}}$  – ожидаемая инфляция.

Шаг 3. Предположим, что инфляционные ожидания формируются согласно (2.4.13):

$$\pi_t^e = (1 - \theta)\bar{\pi} + \theta\pi_{t-1}, \quad (2.4.13)$$

где  $\bar{\pi}$  – целевая инфляция, которую установил центральный банк;

$\theta$  – параметр, который отражает степень заякоренности инфляционных ожиданий. Заякоренными являются инфляционные ожидания  $\pi_t^e$ , при которых ожидаемые значения инфляции в периоды ухудшения и улучшения экономической конъюнктуры равны целевой инфляции центрального банка  $\bar{\pi}$ . Инфляционные ожидания являются заякоренными при  $\theta \rightarrow 0$ .

Шаг 4. Предположим, что в период  $t$  ожидаемый уровень инфляции  $\pi_t^e$  равен фактической инфляции  $\pi_t$ , тогда кривая Филлипса (2.4.12) преобразуется к виду (2.4.14):

$$0 = (m_t + z_t) - \alpha u_n \Rightarrow u_n = \frac{m_t + z_t}{\alpha}, \quad (2.4.14)$$

где  $u_n$  – естественный уровень безработицы. Естественным является уровень безработицы, когда ожидаемый уровень инфляции равен его фактическому значению.

Шаг 5. С учетом (2.4.14) перепишем кривую Филлипса в виде уравнения (2.4.15):

$$\pi_t - \pi_t^e = -\alpha \left( u_t - \frac{m_t + z_t}{\alpha} \right) \Rightarrow \pi_t - \pi_t^e = -\alpha(u_t - u_n), \quad (2.4.15)$$

где  $(u_t - u_n)$  – разрыв безработицы.

Шаг 6. Уровень безработицы составляет  $u_t \triangleq \frac{U_t}{L_t} = \frac{L_t - N_t}{L_t}$ , где  $L_t \triangleq N_t + U_t$  – рабочая сила;  $U_t$  – численность безработного населения;  $N_t$  – численность занятого населения. С учетом формулы для расчета численности занятого населения  $N_t = L_t(1 - u_t)$  перепишем производственную функцию  $Y_t = N_t \Rightarrow Y_t = L_t(1 - u_t)$ . Если уровень безработицы  $u_t$  равен его естественному значению  $u_n$ , тогда выпуск  $Y_t$  достигает своего потенциала  $Y_n = L_t(1 - u_n)$ . Отклонение объема выпуска от его потенциального значения (далее, разрыв выпуска) составит (2.4.16):

$$Y_t - Y_n = -L_t(u_t - u_n). \quad (2.4.16)$$

Шаг 7. С учетом (2.4.16) в кривой Филлипса (2.4.15) заменим разрыв безработицы на разрыв выпуска:

$$\pi_t - \pi_t^e = \frac{\alpha}{L_t}(Y_t - Y_n). \quad (2.4.17)$$

Далее приведем исследования, в которых используются инфляционные ожидания для прогнозирования инфляции. [Faust, Wright, 2013] применили ряд статистических методов для прогнозирования инфляции в США: 1) векторные авторегрессии; 2) кривую Филлипса; 3) модели временной структуры процентных ставок; 4) динамические

стохастические модели общего равновесия (DSGE)<sup>18</sup>; 5) модели ненаблюдаемой компоненты со стохастической волатильностью; 6) байесовское усреднение моделей; а также инфляционные ожидания профессиональных аналитиков. На статистических данных по США за период с I квартала 1960 г. по IV квартал 2011 г. выявлено, что более точные прогнозы инфляции, по сравнению с результатами эконометрических моделей, дает использование инфляционных ожиданий профессиональных аналитиков.

[Петрова, 2019] для оценки инфляционных ожиданий домашних хозяйств в России строит специальный индекс на основе информации по интернет-запросам Google Trends. Статистические данные за период с января 2004 г. по июль 2019 г. демонстрируют, что предложенный индекс повышает точность прогнозирования инфляции методами машинного обучения.

В работе [Angelico et al., 2022] используются статистические данные социальной сети Twitter для оценки инфляционных ожиданий в Италии. Авторы отмечают, что информация из социальных сетей позволяет преодолеть ряд недостатков альтернативных способов измерения инфляционных ожиданий. Во-первых, данные, собираемая из социальных сетей, имеют более высокую частоту по сравнению с опросами респондентов относительно инфляции. Во-вторых, информация, предоставляемая социальными сетями, отражает инфляционные ожидания потребителей, а статистика по финансовым показателям – инфляционные ожидания инвесторов и аналитиков. Помимо динамики цен финансовые показатели отражают премию за риск, что затрудняет оценку инфляционных ожиданий. На статистических данных по Италии [Angelico et al., 2022] выявили, что предложенный индекс на основе социальной сети Twitter положительно и статистически значимо взаимосвязан с опросными данными по инфляции и с финансовыми контрактами, которые привязаны к темпам роста цен. Эконометрические модели, построенные с учетом предложенного индекса, по сравнению с авторегрессией точнее прогнозируют инфляционные ожидания потребителей.

[Coibion et al., 2018] также перечисляют ряд преимуществ и недостатков оценки инфляционных ожиданий на основе опросов и финансовых показателей. Финансовые, биржевые показатели инфляционных ожиданий имеют высокую частоту, но подвержены влиянию неценовых факторов. Опросы профессиональных аналитиков позволяют получить

---

<sup>18</sup> Среди российских исследований отметим работы [Крепцев, Селезнев, 2017; Kreptsev, Seleznev, 2018; Sharafutdinov, 2023], которые посвящены прогнозированию инфляции в России с помощью динамических стохастических моделей общего равновесия (DSGE). Также DSGE модели применяются для анализа основных макроэкономических показателей (в том числе и инфляции) в России при структурных шоках (цен на нефть, торговых условий) [Полбин, 2013, 2014].

более длинные временные ряды, но аналитики могут не раскрывать свои истинные прогнозы. Оценки домашних хозяйств могут быть неустойчивыми к формату проведения опросов. [Coibion et al., 2018] на примере США выявили, что кривая Филлипса, построенная с учетом опросов домашних хозяйств, точнее прогнозирует инфляцию по сравнению с альтернативными способами измерения инфляционных ожиданий, использующими опросы профессиональных аналитиков, оценки ФРС и финансовые показатели.

[Голощапова, Андреев, 2017] отмечают, что построение оценки инфляционных ожиданий на основе опросов сопряжено с финансовыми и организационными издержками, возникающими в процессе анкетирования, ввода результатов опросов в программное обеспечение, проверки и исправления ошибок при повторном анкетировании респондентов. Недостатком финансовых показателей для измерения инфляционных ожиданий является то, что биржевые показатели (например, доходность облигаций) могут учитывать не только уровень инфляции, но и кредитный риск, а также риск ликвидности. В силу чего, [Голощапова, Андреев, 2017], чтобы оценить инфляционные ожидания в России, использовали информацию, полученную из экономических средств массовой информации (СМИ), таких как: «Ведомости», «РБК», «Эксперт», «Коммерсантъ». Авторы приходят к выводу, что оценка инфляционных ожиданий на основе СМИ за период 2014-2016 гг. имеет высокую корреляцию: (1) с опросами населения, которые проводит ООО «инФОМ»; (2) с ценами на нефть, валютным курсом рубля к доллару США, ключевой ставкой Банка России.

По аналогии с [Angelico et al., 2022] в работе [Shulyak, 2022] используется информация из социальных сетей для оценки ожиданий экономических агентов. Предложенный индекс рассчитывается как разность между количеством положительных и отрицательных комментариев в постах, которые связаны с экономической проблематикой. Посты социальной сети «ВКонтакте» были поделены на 14 кластеров на основе алгоритма семплирования Гиббса для распределения Дирихле. На статистических данных за период с января 2013 г. по декабрь 2020 г. получено, что по сравнению с авторегрессией первого порядка модели с учетом построенного индекса (Shulyak, 2022) точнее прогнозируют инфляцию в России.

Помимо информации из социальных сетей в российских исследованиях прогнозируется темп роста цен с учетом инфляционных ожиданий, которые оцениваются на основе опросов аналитиков. [Perevyshin, 2024] добавляет опросы аналитиков Центра развития НИУ ВШЭ в кривую Филлипса с разрывом выпуска и адаптивными инфляционными ожиданиями, а также в векторную авторегрессию с первым лагом VAR(1)

и четырьмя переменными: инфляцией, разрывом выпуска, валютным курсом рубля к доллару США, процентной ставкой RUONIA. При этом учет инфляционных ожиданий не повышает точность прогноза инфляции с помощью кривой Филлипса. Однако добавление оценок аналитиков по темпам роста цен повышает точность прогноза инфляции векторной авторегрессией по сравнению с VAR(1) без инфляционных ожиданий.

Таким образом, большинство научных работ не отвергают гипотезу о том, что при изучении и прогнозировании динамики цен необходимо учитывать инфляционные ожидания экономических агентов.

## 2.5. Формирование выборки для прогноза российской инфляции

В главе 2 мы систематизировали теоретические каналы и эмпирические оценки влияния на инфляцию ключевых макроэкономических показателей, в том числе: 1) уровня и разрыва безработицы (параграф 2.1); 2) уровня и разрыва выпуска (параграф 2.2); 3) показателей финансовой системы (параграф 2.3); 4) инфляционных ожиданий экономических агентов (параграф 2.4). В Таблице 2.5.1 приведены научные работы, в которых учитывались вышеперечисленные макроэкономические показатели при прогнозировании инфляции.

*Таблица 2.5.1 – Обзор научных работ, в которых учитываются группы макроэкономических показателей при прогнозировании инфляции*

Исследование	Макроэкономические факторы инфляции
[Stock, Watson, 2010; Styrin, 2019; Banbura & Bobeica, 2023; Картаев, Беседовская, 2023]	Показатели рынка труда: уровень безработицы, разрыв безработицы, номинальная заработная плата
[Stock, Watson, 1999; Перевышин, 2022; Banbura, Bobeica, 2023; Medeiros et al., 2023]	Показатели производственного сектора: уровень и разрыв выпуска, объем промышленного производства, оборот розничной торговли и стоимость услуг, предоставленных населению, загрузка производственных мощностей, экспорт
[Stock, Watson, 2003, 2008; Jacobson, Karlsson, 2004; Estrella, 2005; Ang et al., 2006; Koop, Korobilis, 2012; Giannone et al., 2014; Пестова, Мамонов, 2016; Третьяков, Фокин, 2021; Перевышин, 2022; Banbura, Bobeica, 2023; Картаев, Беседовская, 2023; Semiturkin, Shevelev, 2023]	Показатели финансового сектора: рыночные процентные ставки, курсы национальных валют, цены на продовольственные товары и энергоносители, монетарные показатели, доходности облигаций, индексы фондового рынка

## Продолжение Таблицы 2.5.1

Исследование	Макроэкономические факторы инфляции
[Ang et al., 2007; Koop, Korobilis, 2012; Faust, Wright, 2013; Coibion et al., 2018; Петрова, 2019; Angelico et al., 2022; Kohlscheen, 2022; Shulyak, 2022; Perevyshin, 2024]	Инфляционные ожидания экономических агентов

*Источник: составлено автором.*

В ряде исследований одновременно перечисляются несколько указанных выше факторов повышения инфляции: рост цен на сырьевые товары, несоответствие между спросом и предложением из-за задержек поставок товаров, эффекты экономической политики. Так, [Акиндинова и др., 2022] отмечают, что стимулирующие меры денежно-кредитной политики Европейского центрального банка (ЕЦБ) и ФРС в I квартале 2021 г. являются одной из причин повышения инфляции со II квартала 2021 г. Вторым фактором повышения инфляции в период пандемического кризиса являлся дефицит предложения из-за задержек поставок конечных и промежуточных товаров. Сокращение рабочей силы и рост трудовых издержек также выступают в качестве ключевых факторов повышения инфляции в середине 2020 г.

[Акиндинова и др., 2022] отмечают, что сокращение уровня занятости было связано как с ухудшением эпидемиологической ситуации, так и с дефицитом работников-мигрантов из-за ограничений по трансграничным перемещениям. Также вклад роста цен на продовольствие в повышение инфляции в США составил 28%, что связано с низкой урожайностью из-за неблагоприятных погодных условий. В I квартале 2020 г. основным фактором повышения инфляции в России был рост цен на продовольственные товары из-за ажиотажного спроса. В этот же период правительство придерживалось стимулирующей бюджетно-налоговой политики, чтобы помочь домашним хозяйствам и частным компаниям выйти из пандемического кризиса, что также являлось фактором повышения инфляции в середине 2020 г. Наряду с ростом цен на товары внутренних производителей наблюдалось повышение цен на товары, импортируемые из стран, правительства которых также предпринимали стимулирующие меры для восстановления экономики после коронавирусной инфекции. Последующее регулирование цен на услуги позволили замедлить рост общего уровня цен в России в IV квартале 2020 г.

[Акиндинова и др., 2022] связывают понижение российской инфляции в III квартале 2021 г. с государственным регулированием цен на продовольственные товары. Повышению инфляции в Российской Федерации в IV квартале 2021 г. могло способствовать увеличение

социальных трансфертов. Вклад внешних факторов в повышение инфляции в России стал заметен в I квартале 2022 г. Однако стремительный рост цен из-за санкций был сдержан мерами Банка России, который проводил валютные интервенции, повысил ключевую ставку до 20%, снизил нормативы обязательных резервов, приостанавливал торги ценными бумагами на Московской Бирже; устанавливал ограничения на мобильность иностранных валют.

[Goryunov et al., 2023] также перечисляют ряд факторов повышения инфляции за период 2020-2022 гг. На начальном периоде пандемического кризиса в Великобритании, Китае, США и Еврозоне наблюдалось замедление инфляции из-за сокращения потребительского спроса. Центральные банки развитых западных стран придерживались стимулирующей денежно-кредитной политики для выхода экономики из пандемического кризиса. Инфляция в мировой экономике начала повышаться в начале 2021 г. и оставалась высокой до середины 2022 г.

[Goryunov et al., 2023] относят к числу факторов повышения инфляции в развитых странах несоответствие между агрегированным спросом и предложением из-за временной задержки логистических поставок конечных товаров и производственных ресурсов. Вторым фактором повышения инфляции является стимулирующая бюджетно-налоговая политика, проводившаяся в форме субсидий домашним хозяйствам и частным компаниям. Общая стоимость мер стимулирующей фискальной политики в странах G20 составила 8,4 трлн. долларов США. В начале 2021 г. с улучшением эпидемиологической ситуации агрегированный спрос начал восстанавливаться. Третьим фактором повышения инфляции с середины 2020 г. стал рост цен на сырьевые товары: 30% роста потребительских цен в странах ОЭСР приходилось на продовольственные товары и энергоносители. Четвертым фактором повышения инфляции в развитых странах являлся начавшийся в конце 2021 г. цикл ужесточения денежно-кредитной политики.

Таким образом, на основе систематизации исследований можно сформировать пять групп факторов инфляции с использованием, во-первых, теоретических механизмов, характеризующих взаимосвязи между динамикой цен и показателями экономической конъюнктуры; и, во-вторых, полученных в научных работах эмпирических результатов, позволяющих выделить макроэкономические показатели, учет которых повышает точность прогнозов инфляции.

*Первая группа* состоит из показателей рынка труда: уровня безработицы [Phillips, 1958; Fisher, 1978] и заработной платы в номинальном выражении [Styrin, 2019].

Трансмиссионный механизм здесь заключается в следующем (см. параграф 2.1): снижение доли безработного населения ассоциируется с повышением заработной платы в номинальном выражении → ускорение темпов роста цен → необходимость повышения заработных плат в номинальном выражении (спираль «заработная плата-цены»).

Ко *второй группе* относятся показатели агрегированного спроса: объем платных услуг населению и оборот розничной торговли [Перевышин, 2022]. Закон Оукена и обобщенная кривая Филлипса позволяют аналитически вывести взаимосвязь между выпуском и инфляцией. Согласно кривой Филлипса, наблюдается взаимосвязь между неожиданной инфляцией (отклонением инфляции от ее ожидаемой величины) и разрывом безработицы (отклонением безработицы от ее естественного уровня). В свою очередь, согласно закону Оукена существует взаимосвязь между разрывами выпуска и безработицы (см. параграф 2.2).

*Третью группу* составляют показатели финансовой системы: кредиты, выданные частному сектору [Styrin, 2019]; доходность государственных облигаций [Stock, Watson, 2003; Estrella, 2005] и денежные агрегаты [Forni et al., 2003; Pavlov, 2020]. Учет показателей финансовой системы при составлении прогнозов динамики цен объясняется гипотезой ожиданий. Согласно этой гипотезе, процентные ставки характеризуют ожидания экономических агентов в отношении денежно-кредитной политики, которая напрямую влияет на динамику цен и агрегированный спрос<sup>19</sup> (см. параграф 2.3).

*Четвертая группа* включает инфляционные ожидания [Coibion et al., 2018; Angelico et al., 2022; Shulyak, 2022; Kinlaw et al., 2022]. Важность учета инфляционных ожиданий при прогнозе динамики цен объясняется тем, что экономические агенты заинтересованы в получении доходов в реальном выражении и как следствие учитывают сценарные темпы роста цен при планировании контрактов, определяющих уровни номинальной заработной платы. Разработке кривой Филлипса, учитывающей инфляционные ожидания, посвящены исследования [Friedman, 1968; Phelps, 1968].

К *пятой группе* относятся показатели монетарной и фискальной политики: процентные ставки MIACR [Третьяков, Фокин, 2021] и RUONIA [Перевышин, 2022]; объем государственного долга [Cochrane, 2001; Sims, 2010; Araujo, Gaglionne, 2023]; государственные расходы [Kinlaw et al., 2022], доходы государственного бюджета.

---

<sup>19</sup> Аналитический вывод взаимосвязи между ожидаемой динамикой цен (ожидаемым выпуском) и разностью долгосрочных и краткосрочных процентных ставок посредством объединения кривой Филлипса, правила Тейлора и уравнения Фишера (для процентной ставки в номинальном выражении) представлен в работе [Estrella, 2005].

Трансмиссионный механизм схематично можно описать так: стимулирующая монетарная и фискальная политика → смягчение условий на финансовом рынке и повышение агрегированного спроса → ускорение темпов роста цен.

*Шестую группу* формируют показатели мировой экономики: цены на энергоносители и продовольственные товары [Kiselev, Zhivaykina, 2020; Абрамов и др., 2022]; инфляция в еврозоне [Nagy, Tengey, 2018] и США [Ditzen, Ravazzolo, 2022]; валютные курсы [Андреев, 2019; Хабибуллин, 2019; Saul, 2021; Semiturkin, Shevelev, 2023]. Влияние мировой экономики на инфляцию в отдельных странах имеет как прямой, так и косвенный характер. Прямой трансмиссионный механизм проявляется в росте цен импортных товаров. Косвенный канал заключается в повышении мирового спроса на товары и услуги, произведенные в национальной экономике, следствием чего является ускорение инфляция [Абрамов и др., 2022]. Помимо этого повышение цен на энергоносители обуславливает рост цен в странах-импортерах сырьевых товаров через увеличение производственных издержек, а в странах-экспортерах сырьевых товаров – через рост агрегированного спроса вследствие увеличения доходов от экспорта.

Опираясь на разработанную методологию исследования (см. главу 1), а также анализ трансмиссионных каналов и эмпирических оценок влияния макроэкономических показателей на динамику цен (см. главу 2), перейдем к выработке прогнозов инфляции в Российской Федерации ансамблевыми и нейросетевыми методами машинного обучения. Описанию результатов прогнозирования посвящена следующая глава 3.

### Глава 3. Использование ансамблевых и нейросетевых методов для прогнозирования инфляции в России<sup>20</sup>

Настоящая глава посвящена применению предложенных в диссертации ансамблевых и нейросетевых методов и их комбинаций к прогнозированию инфляции в российской экономике. В начале параграфа 3.1 приводится описание множества объясняющих переменных, на основе которого прогнозируется инфляция в России. Далее следует описание статистических данных, в которых учитываются пересмотры ранее опубликованной статистической информации по макроэкономическим показателям. Затем описывается алгоритм преобразования выборки в трехмерную матрицу, блочную матрицу макроэкономических показателей. Параграф 3.2 содержит алгоритм прогнозирования российской инфляции модифицированными методами машинного обучения и их комбинациями. Результаты разработанных алгоритмов обработки статистических данных и прогнозирования инфляции ансамблевыми и нейросетевыми методами обсуждаются в параграфе 3.3.

#### 3.1. Описание статистических данных для прогноза динамики цен в России

Наряду с методологическим аспектом (см. главу 1) важным аспектом прогнозирования инфляции является получение выборки, которая позволит построить наиболее точный прогноз динамики цен. Выборку мы определяем как множество макроэкономических переменных. Более подробная информация по используемой выборке приведена в Таблице 3.1.1.

Темп роста индекса потребительских цен (ИПЦ) в % к соответствующему месяцу предыдущего года (г/г), является ключевой переменной прогнозирования. Объясняющие факторы проходят три этапа предобработки: учитывается первый лаг, преобразование к формату г/г, центрирование и нормирование<sup>21</sup>(3.1.1):

$$z_t = \frac{x_t - x_{min}}{x_{max} - x_{min}}, \quad (3.1.1)$$

---

<sup>20</sup> Результаты раздела отражены в следующих публикациях автора: [Божечкова, Джункеев, 2024; Джункеев, 2022, 2024].

<sup>21</sup> Sklearn Min Max Scaler / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html> (дата обращения: 06.02.2024)

где  $x_t$  — исходное значение переменной в период  $t$ ;

$x_{max}$  — максимальное значение  $x_t$  на тренировочном множестве;

$x_{min}$  — минимальное значение  $x_t$  на тренировочном множестве.

Выборка показателей формируется на базе статистической информации, которую публикует Федеральная служба государственной статистики (Росстат), Министерство финансов Российской Федерации, Банк России, а также ряд международных организаций.

Таблица 3.1.1 – Множество макроэкономических показателей, которые используются для прогнозирования российской инфляции

Показатель	Источник
Индекс потребительских цен	Росстат <sup>22</sup>
Грузооборот транспорта, включая коммерческий и некоммерческий	Росстат
Официальный курс доллара США по отношению к рублю	Росстат
Официальный курс евро по отношению к рублю	Росстат
Оборот розничной торговли: пищевые продукты, включая напитки и табачные изделия	Росстат
Оборот розничной торговли: непродовольственные товары	Росстат
Объем платных услуг населению	Росстат
Кредиты, депозиты и прочие средства, предоставленные корпоративным клиентам, физическим лицам и кредитным организациям	Росстат
Численность официально зарегистрированных безработных в органах служб занятости населения	Росстат
Среднемесячная номинальная начисленная заработная плата работников организаций	Росстат
Нефтегазовые доходы государственного бюджета	Министерство финансов Российской Федерации <sup>23</sup>
Ненефтегазовые доходы государственного бюджета	Министерство финансов Российской Федерации
Государственные расходы	Министерство финансов Российской Федерации
Государственный внешний долг	Министерство финансов Российской Федерации <sup>24</sup>
Государственный внутренний долг	Министерство финансов Российской Федерации
Денежный агрегат М2	Банк России <sup>25</sup>
Процентная ставка RUONIA	Банк России <sup>26</sup>
Процентная ставка MIACR	Банк России <sup>27</sup>
Значения кривой бескупонной доходности государственных облигаций (срок до погашения 3 месяца)	Банк России <sup>28</sup>
Значения кривой бескупонной доходности государственных облигаций (срок до погашения 10 лет)	Банк России

<sup>22</sup> Краткосрочные экономические показатели Российской Федерации / Росстат: сайт. URL: <https://rosstat.gov.ru/compendium/document/50802> (дата обращения: 15.01.2024)

<sup>23</sup> Краткая информация об исполнении федерального бюджета / Министерство финансов Российской Федерации: сайт. URL: <https://minfin.gov.ru/ru/statistics/fedbud/execute/> (дата обращения: 17.01.2024)

<sup>24</sup> Государственный внешний и внутренний долг / Министерство финансов Российской Федерации: сайт. URL: [https://minfin.gov.ru/ru/statistics/gov\\_debt/external\\_internal\\_debt/](https://minfin.gov.ru/ru/statistics/gov_debt/external_internal_debt/) (дата обращения: 17.01.2024)

<sup>25</sup> Денежная масса (национальное определение) / Банк России: сайт. URL: <https://www.cbr.ru/statistics/ms/> (дата обращения: 21.01.2024)

<sup>26</sup> Ruble Overnight Index Average / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/ruonia/](https://www.cbr.ru/hd_base/ruonia/) (дата обращения: 21.01.2024)

<sup>27</sup> Показатели ставок межбанковского кредитного рынка группы MIACR / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/mkr/mkr\\_base/](https://www.cbr.ru/hd_base/mkr/mkr_base/) (дата обращения: 21.01.2024)

<sup>28</sup> Кривая бескупонной доходности государственных облигаций / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/zcyc\\_params/](https://www.cbr.ru/hd_base/zcyc_params/) (дата обращения: 21.01.2024)

## Продолжение Таблицы 3.1.1

Показатель	Источник
Цена на нефть марки Brent	FRED St. Louis <sup>29</sup>
Цена на природный газ	FRED St. Louis <sup>30</sup>
Harmonized Indices of Consumer Prices (HICP)	European Central Bank <sup>31</sup>
Индекс цен на продовольственные товары ФАО	Food and Agriculture Organization <sup>32</sup>

*Источник: составлено автором на основе данных Федеральной службы государственной статистики (Росстат), Банка России, Министерства финансов Российской Федерации, Европейского центрального банка, Федерального резервного банка Сент-Луиса.*

Выборка показателей включает информацию за период с января 2012 г. по апрель 2023 г. Объясняется это доступностью статистической информации. Так, статистические данные по фискальной политике доступны с января 2011 г. Далее, обработка объясняющих факторов в темпы роста г/г приводит к тому, что начальной датой выборки является январь 2012 г. Период, на котором оцениваются модели, составляет январь 2012 г. – июль 2019 г. (67% выборки). Точность прогнозов моделей сравнивается на 33% выборки, датируемых августом 2019 г. – апрелем 2023 г.

В научных исследованиях отмечается важность учета пересмотров статистических данных по составлению макроэкономических прогнозов [Croushore, Stark, 2001; Stark, Croushore, 2002]<sup>33</sup>. Для учета пересмотров используются винтажные данные, то есть статистические данные, которые доступны на момент составления прогнозов и могут быть изменены в последующие периоды. При составлении прогнозов инфляции используется база винтажных данных [Gornostaev et al., 2022]. Подробная информация по макроэкономическим показателям из базы винтажных данных приведена в Таблице 3.1.2.

Таблица 3.1.2 – Винтажные данные для прогнозирования инфляции в России

№	Показатель
1	Инвестиции в основной капитал
2	Коммерческий грузооборот транспорта
3	Погрузка грузов на железнодорожном транспорте
4	Оборот розничной торговли, пищевые продукты
5	Оборот розничной торговли, непродовольственные товары
6	Оборот общественного питания
7	Объем платных услуг населению

<sup>29</sup> Crude Oil Prices: Brent – Europe / Federal Reserve Bank of St. Louis: site. URL:

<https://fred.stlouisfed.org/series/DCOILBRETEU> (дата обращения: 22.01.2024)

<sup>30</sup> Global price of Natural gas / Federal Reserve Bank of St. Louis: site. URL:

<https://fred.stlouisfed.org/series/PNGASEUUSDM> (дата обращения: 22.01.2024)

<sup>31</sup> HICP – Overall Euro area / European Central Bank: site. URL:

<https://data.ecb.europa.eu/data/datasets/ICP/ICP.M.U2.Y.000000.3.INX> (дата обращения: 04.02.2024)

<sup>32</sup> FAO Food Price Index / Food and Agriculture Organization of the United States: site. URL:

<https://www.fao.org/worldfoodsituation/foodpricesindex/en/> (дата обращения: 04.02.2024)

<sup>33</sup> В ряде российских работ получено, что пересмотры статистических данных влияют на изменение точности прогнозов инфляции [Mamedli, Shubitov, 2021], безработицы [Джункеев, 2022], валового внутреннего продукта [Божечкова, Джункеев, 2024].

## Продолжение Таблицы 3.1.2

8	Индекс потребительских цен
9	Среднемесячная номинальная начисленная заработная плата работников организаций
10	Экспорт товаров, страны дальнего зарубежья
11	Импорт товаров, страны дальнего зарубежья
12	Экспорт товаров, государства-участники СНГ
13	Численность официально зарегистрированных безработных в органах службы занятости населения (на конец периода), в том числе получают пособие по безработице
14	Валовой внутренний продукт

*Примечание: исследуемый период датируется интервалом со II квартала 2004 г. по II квартал 2020 г. Используются два винтажа: за ноябрь 2020 г. (предварительные данные), за сентябрь 2021 г. (пересмотренные данные). Источник: составлено автором на основе базы винтажных данных [Gornostaev et al., 2022].*

Выборка винтажных данных охватывает период со II квартала 2004 г. по II квартал 2020 г. Объясняющие переменные преобразовываются в показатели темпов роста, в процентах к предыдущему кварталу текущего года. Методы машинного обучения оцениваются на подвыборках (batch) с размерностью в 20 кварталов. Предварительные винтажные данные доступны на ноябрь 2020 г., а пересмотренные винтажные данные – на сентябрь 2021 г. Выбор данных винтажей обусловлен тремя причинами. На момент составления прогнозов наиболее актуальные винтажные данные по квартальным показателям доступны на сентябрь 2021 г. Вторая причина заключается в том, что наибольшие различия среди показателей, приведенных в Таблице 3.1.2, на II квартал 2020 г. выявлены между статистической информацией за ноябрь 2020 г. и сентябрь 2021 г. по сравнению с информацией за декабрь 2020 г.-август 2021 г. и сентябрь 2021 г. В-третьих, статистические данные за I квартал 2004 г. исключаются из выборки, так как объясняющие переменные ИПЦ берутся с одним лагом. После группировки объясняющих переменных, формирования тренировочного и тестового множеств следующим шагом является предобработка данных. Одним из элементов предобработки данных является составление выборки, позволяющая составлять прогнозы предложенными в диссертации модифицированными моделями градиентного бустинга и нейронными сетями. А именно, для обучения сверточных и рекуррентных нейронных сетей мы формируем трехмерный тензор, определяемый как многомерная матрица, согласно *алгоритму 1*.

Алгоритм 1 – формирование трехмерного тензора для обучения нейронных сетей.

1. Устанавливается длина временного интервала (time series length), на котором обучаются нейронные сети:  $\ell = \{12, 24, 36, 48\}$ <sup>34</sup>
2. Устанавливается горизонт прогнозирования  $h \in \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$ .
3. Выборка разделяется на тренировочное  $\Omega_{(n \times \mathcal{P})}^{train}$  и тестовое  $\Omega_{(n \times \mathcal{P})}^{test}$  множества<sup>35</sup>, где  $n$  – общее количество временных периодов,  $\mathcal{P} = (\mathcal{P}^{features} + \mathcal{P}^{target})$  – общее количество переменных:  $\mathcal{P}^{target}$  – объясняемая переменная,  $\mathcal{P}^{features}$  – объясняющие переменные.
4. Формируются два множества: матрица признаков  $\mathcal{X}$  и целевой вектор  $\mathcal{y}$ . Далее, на каждой итерации цикла двумерная *подвыборка* (batch) размерности  $(\ell \times \mathcal{P})$  представляет собой отдельный элемент множества признаков  $\mathcal{X}$ , а двумерная подвыборка размерности  $(\ell \times h)$  – элемент целевого вектора  $\mathcal{y}$ .<sup>36</sup>

На Рисунке 3.1.1 приведен иллюстративный пример результата алгоритма 1 при  $\Omega_{(4 \times 4)}$ ,  $\ell = 2$ ,  $h = 1$ .

$$\begin{array}{ccc}
 \begin{array}{c} \left[ \begin{array}{ccc} x_{1,1} & x_{2,1} & x_{3,1} \\ x_{1,2} & x_{2,2} & x_{3,2} \\ x_{1,3} & x_{2,3} & x_{3,3} \\ x_{1,4} & x_{2,4} & x_{3,4} \end{array} \right] & \begin{array}{c} \left[ \begin{array}{c} y_1 \\ y_2 \\ y_3 \\ y_4 \end{array} \right] \\ \text{целевой вектор} \end{array} \\ \text{матрица признаков} & \text{целевой вектор} \\ \text{исходная выборка } \Omega & \end{array} & \rightarrow & \begin{array}{c} \begin{array}{c} \left[ \begin{array}{ccc} x_{1,1} & x_{2,1} & x_{3,1} & y_1 \\ x_{1,2} & x_{2,2} & x_{3,2} & y_2 \end{array} \right] & \left[ \begin{array}{ccc} x_{1,3} & x_{2,3} & x_{3,3} & y_3 \end{array} \right] \\ \text{X}_1\text{-матрица признаков} & \text{y}_1\text{-целевой вектор} \\ \begin{array}{c} \left[ \begin{array}{ccc} x_{1,2} & x_{2,2} & x_{3,2} & y_2 \\ x_{1,3} & x_{2,3} & x_{3,3} & y_3 \end{array} \right] & \left[ \begin{array}{ccc} x_{1,4} & x_{2,4} & x_{3,4} & y_4 \end{array} \right] \\ \text{X}_1\text{-матрица признаков} & \text{y}_2\text{-целевой вектор} \end{array} \\ \text{преобразованная выборка } \tilde{\Omega} & \end{array}
 \end{array}
 \end{array}$$

Рисунок 3.1.1 – Преобразование исходной выборки в трехмерный тензор для обучения нейросетевых методов. Источник: составлено автором

В частности, при исходной выборке размерностью (4 месяца  $\times$  4 переменные),  $\Omega_{(4 \times 4)}$ , а также  $\ell = 2$ ,  $h = 1$  получается преобразованная выборка  $\tilde{\Omega}$ , которая состоит из двух матриц: (1) тензор объясняющих переменных  $\mathcal{X}$  размерностью (2 подвыборки  $\times$  2 месяца  $\times$  4 переменные); (2) тензор целевой переменной  $\mathcal{y}$  размерностью (2 подвыборки  $\times$  1 месяц  $\times$  4 переменные).

<sup>34</sup> Результаты прогнозирования сравниваются при  $\ell = 24$ . Это обусловлено тем, что при  $\ell = 24$  наблюдаются наиболее точные прогнозы базовой модели авторегрессии первого порядка AR(1) по сравнению с  $\ell = \{12, 36, 48\}$ .

<sup>35</sup> Train test split / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.train\\_test\\_split.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.train_test_split.html) (дата обращения: 06.02.2024)

<sup>36</sup> Техническая реализация для формирования тензора такова: 1) функция Time Series Data From Array. Time series data loading / Keras: site. URL: <https://keras.io/api/preprocessing/timeseries/#timeseriesdatasetfromarray-function> (дата обращения: 08.02.2024); 2) функция Time Series Generator / TensorFlow: site. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/sequence/TimeSeriesGenerator](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/sequence/TimeSeriesGenerator) (дата обращения: 10.02.2024)

Для обучения ансамблевых методов формируется блочная выборка согласно алгоритму 2 с учетом результата, полученного при применении алгоритма 1.

Алгоритм 2 – составление блочной матрицы для обучения моделей градиентного бустинга и случайного леса.

1. Устанавливается длина временного интервала (time series length), на котором обучаются модели градиентного бустинга и случайного леса:  $\ell = \{12, 24, 36, 48\}$
2. Устанавливается горизонт прогнозирования  $h \in \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$
3. Выборка разделяется на тренировочное  $\Omega_{(n \times \mathcal{P})}^{train}$  и тестовое  $\Omega_{(n \times \mathcal{P})}^{test}$  множества, где  $n$  – общее количество временных периодов,  $\mathcal{P} = (\mathcal{P}^{features} + \mathcal{P}^{target})$  – общее количество переменных:  $\mathcal{P}^{target}$  – объясняемая переменная,  $\mathcal{P}^{features}$  – объясняющие переменные.
4. На основе алгоритма 1 определяется размерность трехмерного тензора для нейронных сетей  $\mathcal{X}_{(b, l, \mathcal{P})}$ ,  $\mathcal{Y}_{(b, h, \mathcal{P})}$ .
5. Формируются два множества: матрица признаков  $\tilde{\mathcal{X}}$ , целевой вектор  $\tilde{\mathcal{Y}}$ . Далее, на каждой итерации цикла отдельный элемент информационного множества  $\tilde{\Omega}$  размерности  $((b \cdot \mathcal{P}) \times (\ell + h))$  состоит из двух частей: транспонированная подвыборка матрицы признаков размерности  $(\ell \times \mathcal{P})^T$ , транспонированный целевой вектор размерности  $(h \times \mathcal{P})^T$ .

На Рисунке 3.1.2 приведен пример результата алгоритма 2 при  $\Omega_{(4 \times 4)}$ ,  $\ell = 2$ ,  $h = 1$ .

$$\begin{array}{ccc}
 \begin{array}{|c|} \hline \begin{matrix} x_{1,1} & x_{2,1} & x_{3,1} \\ x_{1,2} & x_{2,2} & x_{3,2} \\ x_{1,3} & x_{2,3} & x_{3,3} \\ x_{1,4} & x_{2,4} & x_{3,4} \end{matrix} \\ \hline \end{array} & \begin{array}{|c|} \hline \begin{matrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{matrix} \\ \hline \end{array} & \rightarrow & \begin{array}{|c|} \hline \begin{matrix} x_{1,1} & x_{1,2} \\ x_{2,1} & x_{2,2} \\ x_{3,1} & x_{3,1} \\ y_1 & y_2 \\ x_{1,2} & x_{1,3} \\ x_{2,2} & x_{2,3} \\ x_{3,2} & x_{3,3} \\ y_2 & y_3 \end{matrix} \\ \hline \end{array} & \begin{array}{|c|} \hline \begin{matrix} x_{1,3} \\ x_{2,3} \\ x_{3,3} \\ y_3 \\ x_{1,4} \\ x_{2,4} \\ x_{3,4} \\ y_4 \end{matrix} \\ \hline \end{array} \\
 \underbrace{\hspace{10em}}_{\text{исходная выборка } \Omega} & & & \underbrace{\hspace{10em}}_{\text{преобразованная выборка } \tilde{\Omega}}
 \end{array}$$

Рисунок 3.1.2 – Преобразование исходной выборки в блочную выборку для обучения ансамблевых методов. Источник: составлено автором

С учетом описания выборки и способов преобразования данных перейдем к алгоритму прогнозирования инфляции в России на основе модифицированных моделей градиентного бустинга и нейронных сетей и их комбинаций, чему посвящен следующий раздел 3.2.

### 3.2. Алгоритм прогнозирования инфляции в России

С учетом итоговой предобработки данных (см. параграф 3.1) инфляция в России прогнозируется согласно алгоритму 3:

*Алгоритм 3 – прогнозирование инфляции на основе ансамблевых и нейросетевых методов машинного обучения.*

1. Выбирается тренировочное множество и задается сетка априорных гиперпараметров  $\mathcal{G}_{ensemble}, \mathcal{G}_{networks}$ . Таблица 3.2.1 и Таблица 3.2.2 содержат подробную информацию по априорным гиперпараметрам моделей градиентного бустинга, случайного леса и нейронных сетей.

Таблица 3.2.1 – Начальные гиперпараметры градиентного бустинга, случайного леса

Модель	Сетка априорных гиперпараметров
AdaBoost <sup>37</sup>	Количество деревьев: {200, ..., 800, 1000}
Bagging <sup>38</sup>	Количество деревьев: {200, ..., 800, 1000}
CatBoost <sup>39</sup>	Количество деревьев: {200, ..., 800, 1000}
LightGBM <sup>40</sup>	Количество деревьев: {200, ..., 800, 1000}
Случайный лес <sup>41</sup>	Количество деревьев: {200, ..., 800, 1000}
Градиентный бустинг Sklearn <sup>42</sup>	Количество деревьев: {200, ..., 800, 1000}
XGBoost <sup>43</sup>	Количество деревьев: {200, ..., 800, 1000}
<i>Общие конфигурации</i>	Кросс-валидация из 5 разбиений: Time Series Split <sup>44</sup> Поиск оптимальных гиперпараметров: Grid Search <sup>45</sup> Функция минимизации (loss function): $l_2$ -квадратичная функция

Источник: составлено автором.

<sup>37</sup> AdaBoostRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.AdaBoostRegressor.html> (дата обращения: 21.02.2024)

<sup>38</sup> BaggingRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.BaggingRegressor.html> (дата обращения: 21.02.2024)

<sup>39</sup> CatBoostRegressor / CatBoost: site. URL: [https://catboost.ai/en/docs/concepts/python-reference\\_catboostregressor](https://catboost.ai/en/docs/concepts/python-reference_catboostregressor) (дата обращения: 22.02.2024)

<sup>40</sup> LGBMRegressor / LightGBM / URL: <https://lightgbm.readthedocs.io/en/latest/pythonapi/lightgbm.LGBMRegressor.html> (дата обращения: 22.02.2024)

<sup>41</sup> RandomForestRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html> (дата обращения: 22.02.2024)

<sup>42</sup> GradientBoostingRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html> (дата обращения: 22.02.2024)

<sup>43</sup> XGBRegressor / XGBoost: site. URL: [https://xgboost.readthedocs.io/en/release\\_3.2.0/python/python\\_api.html#xgboost.XGBRegressor](https://xgboost.readthedocs.io/en/release_3.2.0/python/python_api.html#xgboost.XGBRegressor) (дата обращения: 22.02.2024)

<sup>44</sup> TimeSeriesSplit / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.TimeSeriesSplit.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html) (дата обращения: 19.02.2024)

<sup>45</sup> GridSearchCV / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html) (дата обращения: 19.02.2024)

По результатам обзора исследований формируются начальные гиперпараметры методов машинного обучения: модели случайного леса [Baybuza, 2018]; модели градиентного бустинга [Shulyak, 2022]; ANN [Pavlov, 2020]; CNN [Aanes, Gullien, 2018]; GRU [Barkan et al., 2022]; LSTM [Paranhos, 2021].

Таблица 3.2.2 – Начальные гиперпараметры нейронных сетей

Модель	Сетка априорных гиперпараметров
Полносвязные нейронные сети (artificial neural networks, ANN) <sup>46</sup>	Количество узлов первого слоя: {64, ..., 512, 1024} Функция активации входного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }. Функция активации выходного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }.
Сверточные нейронные сети (convolutional neural networks, CNN) <sup>47</sup>	Размерность фильтра (filter): 64. Размерность матрицы сверточного ядра (kernel size): 3 × 3. Количество узлов первого скрытого слоя: {64, ..., 512, 1024}. Max Pooling: 2. Функция активации сверточного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }. Функция активации выходного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }.
Рекуррентные нейронные сети (recurrent neural networks, RNN) <sup>48</sup>	Количество узлов первого скрытого слоя: {64, ..., 512, 1024}. Функция активации рекуррентного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }. Функция активации выходного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }.
Модель долгой краткосрочной памяти (long short-term memory, LSTM) <sup>49</sup>	Количество узлов первого скрытого слоя: {64, ..., 512, 1024}. Функция активации входного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }. Функция активации выходного слоя: { <i>linear</i> , <i>relu</i> , <i>tanh</i> }.
<i>Общие конфигурации</i>	Начальные веса генерируются согласно равномерному распределению [Glorot, Bengio, 2010]. Алгоритм стохастической оптимизации: [Kingma, Ba, 2017]. Количество эпох: 500.

Источник: составлено автором.

2. Подбор оптимальных гиперпараметров ансамблевых  $\mathcal{F}_{ensemble}$  и нейросетевых  $\mathcal{F}_{networks}$  методов машинного обучения основан на минимизации среднеквадратичной

<sup>46</sup> Dense Layer / Keras: site. URL: [https://keras.io/api/layers/core\\_layers/dense/](https://keras.io/api/layers/core_layers/dense/) (дата обращения: 06.03.2024)

<sup>47</sup> Conv1D / TensorFlow: site. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/layers/Conv1D](https://www.tensorflow.org/api_docs/python/tf/keras/layers/Conv1D) (дата обращения: 09.03.2024)

<sup>48</sup> SimpleRNN Layer / Keras: site. URL: [https://keras.io/api/layers/recurrent\\_layers/simple\\_rnn/](https://keras.io/api/layers/recurrent_layers/simple_rnn/) (дата обращения: 06.03.2024)

<sup>49</sup> LSTM Layer / Keras: site. URL: [https://keras.io/api/layers/recurrent\\_layers/lstm/](https://keras.io/api/layers/recurrent_layers/lstm/) (дата обращения: 06.03.2024)

ошибки прогноза (mean squared error, MSE). В Таблице 3.2.3 приведены оптимальные гиперпараметры ансамблевых и нейросетевых методов машинного обучения.

Таблица 3.2.3 – Оптимальные гиперпараметры моделей градиентного бустинга, случайного леса и нейронных сетей, полученные на основе минимизации среднеквадратичной ошибки прогноза

Метод машинного обучения: Гиперпараметр	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
AdaBoost: I	1000	600	600	800	800	800	600	600	600	800	800	1000
ANN: II III IV	256 Linear Tanh	512 Tanh Linear	512 Tanh RELU	512 Tanh RELU	512 Tanh RELU	256 Linear Tanh	256 Tanh RELU	256 Tanh RELU	512 Tanh Linear	256 Tanh RELU	256 Tanh RELU	256 Linear Tanh
Bagging: I	200	200	400	400	200	400	400	200	400	200	200	200
CatBoost: I	800	800	600	1000	1000	800	1000	1000	1000	800	1000	1000
CNN: II III IV	256 Linear Tanh	512 Linear Tanh	512 Tanh Linear	256 Linear Tanh	256 Linear Tanh	512 RELU RELU	256 RELU RELU	256 RELU RELU	256 RELU RELU	256 Tanh Tanh	256 Linear Tanh	512 Tanh Linear
RNN: II III IV	512 Tanh RELU	512 Tanh Tanh	256 Tanh Tanh	512 Tanh RELU	512 Tanh RELU	256 Tanh Tanh	512 Tanh RELU	512 Linear RELU	512 Tanh Tanh	512 Tanh RELU	512 Tanh RELU	512 Tanh RELU
Sklearn Gradient Boosting: I	400	400	600	400	1000	600	600	800	800	600	400	400
XGBoost: I	600	600	600	600	600	600	600	600	600	600	600	600

Примечание: символы «I», «II», «III», «IV» означают соответственно количество деревьев ансамблевых моделей, количество нейронов входного слоя, функцию активации входного слоя, функцию активации выходного слоя. «Linear», «Tanh», «RELU» обозначает линейную функцию активации, гиперболический тангенс, rectified linear unit. Источник: составлено автором.

3. Прогнозы составляются на основе рекурсивного подхода. Последняя подвыборка тренировочного множества является первой итерацией прогнозирования, на основе которой формируется прогноз. Далее, информация первой даты последней подвыборки тренировочного множества заменяется на статистические данные второй даты, а информация последней даты – на прогноз. Аналогичным образом на каждом цикле обновляется подвыборка, на основе которой составляются прогнозы. При этом количество циклов определяется горизонтом прогнозирования.

4. На тестовом множестве  $\mathcal{T}$  по горизонтам  $h \in \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$  точность моделей градиентного бустинга, случайного леса и нейронных сетей сравнивается

с точностью авторегрессии первого порядка [Stock, Watson, 2007; Baubyza, 2018; Kohlscheen, 2021; Shulyak, 2022] на основе информационного критерия Акаики (Akaike Information Criterion, AIC) (следуя, [Inoue, Kilian, 2006], среднеквадратической ошибки прогноза (root mean squared error, RMSE) и теста Дибольда-Мариано [Diebold, Mariano, 1995] с поправкой на объем выборки [Harvey et al., 1997].

5. Помимо отдельных методов машинного обучения для прогноза инфляции применяются их комбинации (см. параграф 1.5): 1) ансамблевые методы; 2) нейросетевые методы; 3) доверительное множество моделей [Hansen et al., 2011]. Для технической реализации методов комбинирования применяются библиотеки R ForecastComb<sup>50</sup> [Wiess et al., 2018], MCS<sup>51</sup> [Bernardi, Catania, 2018].

Подробная информация по весам ансамблевых и нейросетевых методов в их комбинации приведена в Таблице 3.2.4.

Таблица 3.2.4 – Веса методов машинного обучения в их комбинации

Модель: Доля в комбинации моделей (процент)	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
Комбинация нейросетевых методов												
CNN	0.189	0.178	0.200	0.232	0.203	0.222	0.237	0.259	0.209	0.217	0.199	0.188
ANN	0.321	0.203	0.249	0.179	0.210	0.244	0.201	0.190	0.218	0.214	0.208	0.209
RNN	0.172	0.156	0.189	0.236	0.242	0.175	0.170	0.184	0.190	0.205	0.262	0.187
LSTM	0.167	0.177	0.191	0.182	0.184	0.177	0.194	0.166	0.174	0.182	0.178	0.219
GRU	0.151	0.287	0.171	0.170	0.161	0.181	0.198	0.201	0.209	0.182	0.153	0.197
Комбинация ансамблевых методов												
CatBoost	0.173	0.162	0.142	0.170	0.173	0.157	0.185	0.190	0.186	0.160	0.179	0.184
LightGBM	0.208	0.206	0.199	0.192	0.202	0.213	0.214	0.205	0.201	0.191	0.209	0.225
AdaBoost	0.204	0.244	0.228	0.222	0.229	0.235	0.220	0.214	0.228	0.228	0.222	0.204
Random Forest	0.220	0.206	0.213	0.206	0.190	0.204	0.189	0.190	0.192	0.195	0.190	0.187
XGBoost	0.196	0.181	0.215	0.209	0.206	0.190	0.192	0.201	0.192	0.226	0.199	0.200
Комбинация ансамблевых и нейросетевых методов												
CLARA	0.315	0.343	0.431	0.483	0.482	0.399	0.441	0.383	0.364	0.486	0.565	0.451
CARLSON	0.685	0.657	0.570	0.517	0.518	0.602	0.559	0.617	0.636	0.514	0.435	0.549
Доверительное множество моделей												
MCS	ANN 1,000	GRU 1,000	ANN 1,000	RNN 1,000	RNN 1,000	ANN 1,000	CNN 1,000	CNN 1,000	ANN 1,000	AdaBoost: 0,203 ANN: 0,200 CNN: 0,202 RNN: 0,191 XGBoost: 0,202	AdaBoost 1,000	LSTM 1,000

Источник: расчеты автора.

<sup>50</sup> ForecastComb / Ceweiss: site. URL: <https://github.com/ceweiss/ForecastComb> (дата обращения: 21.03.2024)

<sup>51</sup> Model Confidence Set Procedure / CRAN R Project: site. URL: <https://cran.r-project.org/web/packages/MCS/index.html> (дата обращения: 22.03.2024)

6. Помимо авторегрессии первого порядка точность ансамблевых и нейросетевых методов машинного обучения сравнивается с точностью прогноза двух треугольных форм кривой Филлипа [Картаев, Беседовская, 2023]: 1) 24 лага темпов прироста общего уровня цен, уровня безработицы, денежного агрегата M2 (далее, PC-M2); 2) 24 лага темпов прироста общего уровня цен, уровня безработицы, цен на нефть марки Brent (далее, PC-OIL). Четвертой эталонной моделью является байесовская векторная авторегрессия (Bayesian Vector Autoregression, BVAR) [Sims, Zha, 1998; Giannone et al., 2015]. В таблице 3.2.5 приведены априорные и оптимальные гиперпараметры байесовской векторной авторегрессии.

Таблица 3.2.5 – Априорные и оптимальные гиперпараметры байесовской векторной авторегрессии

Гиперпараметры	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
$\lambda$	0.164	0.163	0.165	0.175	0.172	0.172	0.177	0.180	0.182	0.180	0.187	0.186
$SOC$	0.472	0.620	0.806	0.895	0.686	0.681	0.696	0.844	0.838	0.655	0.639	0.623
$SUR$	0.135	0.149	0.169	0.184	0.155	0.152	0.142	0.150	0.127	0.112	0.113	0.107
Априорные гиперпараметры	С увеличением $\lambda$ апостериорное распределение придает больший вес информации выборочной совокупности по сравнению с априорными значениями. Параметр $\alpha$ контролирует сжатие для наблюдений с более отдаленным лагом. Параметр SOC – sum-of-coefficients prior. Параметр SUR – single-unit-root prior. Числовые характеристики распределения для $\lambda$ : мода 0,2; стандартное отклонение 0,4; минимальное значение 0,0001; максимальное значение 5. Числовые характеристики распределения для $\alpha$ : мода 2. Параметры распределения для $SOC$ и $SUR$ : мода 1; минимальное значение 0,0001; максимальное значение 50, что рекомендовано [Sims, Zha, 1998; Giannone et al., 2015].											

Источник: расчеты автора.

7. Применение вектора Шепли [Lundberg, Lee, 2020; Chen et al., 2023] для выявления значимых объясняющих переменных в прогнозах наиболее точных методов машинного обучения. Для технической реализации алгоритма используется библиотека shap<sup>52</sup>.

<sup>52</sup> Shapley Additive Explanations / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/index.html> (дата обращения: 05.04.2024)

В общем виде для того, чтобы интерпретировать результаты модели  $f$  используется ее аппроксимация  $g$ , которую определим как пояснительную модель (explanation model). Вектор Шепли относится к локальным методам аппроксимации, согласно которым: (1) пояснительная модель  $g$  оценивается на сжатом множестве объясняющих переменных  $x'$ , связанным с исходным множеством объясняющих переменных  $x$  модели  $f$  отображением  $x = h_x(x')$ ; (2) пояснительная модель  $g$  и исходная модель  $f$  связаны следующим образом [Lundberg, Lee, 2017]:

$$g(z') \triangleq \phi_0 + \sum_{i=1}^M \phi_i z'_i \approx f[h_x(z')] \text{ при } z' \approx x', \quad (3.2.1)$$

где  $\triangleq$  – оператор тождества;  $z' \in \{0,1\}^M$ ;  $M$  – количество объясняющих переменных сжатого множества  $x'$ .

С учетом отображения  $h_x: \{0,1\} \mapsto x$ , коэффициенты модели (3.2.1)  $\phi_i \in \mathbb{R}$  определяются согласно формуле (3.2.2):

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)], \quad (3.2.2)$$

где  $F$  – исходное множество объясняющих переменных;  $S$  – сжатое множество объясняющих переменных  $S \subseteq F$ ;  $x_S$  – значения объясняющих переменных сжатого множества  $S$ ;  $|F|$  – количество ненулевых элементов исходного множества  $F$ ;  $f_{S \cup \{i\}}$  – прогноз модели, в которой учитывается объясняющая переменная  $i$ ;  $f_S$  – прогноз модели, в которой не учитывается объясняющая переменная  $i$ .

[Lundberg, Lee, 2017] отмечают, что локальные методы аппроксимации (3.2.1) обладают следующими тремя свойствами.

*Свойство локальной точности (P1):*  $f(x) = g(x') \triangleq \phi_0 + \sum_{i=1}^M \phi_i x'_i, x = h_x(x')$ . Таким образом, пояснительная модель  $g$  со сжатым множеством объясняющих переменных  $x'$  соответствует исследуемой модели  $f$  с исходным множеством объясняющих переменных  $x$ .

*Свойство устойчивости к пропущенным наблюдениям (P2):*  $x'_i = 0 \Rightarrow \phi_i = 0$ . Таким образом, пропущенные наблюдения в сжатом множестве объясняющих переменных  $x'$  не влияют на точность пояснительной модели  $g$ .

*Свойство состоятельности (P3):* если для двух моделей  $f$  и  $f'$  выполняется неравенство  $f'_x(z') - f'_x(z' \setminus i) \geq f_x(z') - f_x(z' \setminus i)$ , где  $f_x(z') \triangleq f[h_x(z')]$ ,  $z' \setminus i \triangleq z'_i = 0, z' \in \{0,1\}^M$ , тогда  $\phi_i(f', x) \geq \phi_i(f, x)$ . Таким образом, если точность пояснительной модели  $g$

повышается или не меняется при учете отдельной объясняющей переменной, то коэффициент при этой объясняющей переменной не уменьшается.

[Lundberg, Lee, 2017] теоретически доказали, что пояснительная модель  $g$  (3.2.1) с коэффициентами  $\phi_i$  (3.2.2) является единственным локальным методом с тремя свойствами (P1), (P2), (P3), который позволяет аппроксимировать исследуемую модель  $f$ .

Следующим пунктом новизны настоящей диссертации является изучение изменения точности моделей при пересмотрах информации о макроэкономических переменных. *Алгоритм 4* позволяет оценить влияние пересмотров на точность прогнозов при пересмотрах статистических данных:

*Алгоритм 4 – оценка изменения точности прогнозов при пересмотрах статистических данных.*

1. Применяется *алгоритм 3* для оценки моделей на предварительных винтажах
2. Осуществляется подбор и сохранение оптимальных гиперпараметров моделей, на основе которых выявлена наименьшая RMSE.
3. На основе оптимальных гиперпараметров составляются прогнозы инфляции как на предварительных, так и на пересмотренных винтажах.
4. Точность прогнозов на предварительных и пересмотренных винтажах сравнивается с помощью AIC, RMSE, теста Дибольда-Мариано.

В завершение параграфа резюмируем вклад настоящего исследования в литературу, посвященной прогнозированию инфляции в России. Во-первых, прогнозы инфляции составляются на основе упорядоченного, адаптивного, поправочного градиентных бустингов (см. Параграф 1.3), а также сверточных и рекуррентных нейронных сетей (см. Параграф 1.4). При этом для обучения данных методов машинного обучения необходимо подготовить трехмерный тензор (см. Рисунок 3.1.1) и блочную матрицу (Рисунок 3.1.2). Во-вторых, прогнозы инфляции составляются не только на основе моделей градиентного бустинга, случайного леса, нейронных сетей, но также с помощью их комбинаций (см. Параграф 1.5). В-третьих, оценивается влияние пересмотров статистических данных на точность предложенных в диссертации методов машинного обучения.

В следующем параграфе 3.3 подробнее опишем результаты прогнозирования инфляции в России на основе модифицированных ансамблевых и нейросетевых методов машинного обучения и их комбинаций.

### 3.3. Результаты прогнозирования российской инфляции

Результаты прогнозирования инфляции рассматриваются в четырех аспектах, принимая во внимание: *информационный критерий Акаики; среднеквадратическую ошибку прогноза; влияние пересмотров статистических данных на точность моделей; вектор Шепли.*

*Информационный критерий Акаики.* В Таблице 3.3.1 приведены значения информационного критерия Акаики для ансамблевых и нейросетевых методов машинного обучения, а также их комбинаций.

Согласно информационному критерию Акаики (AIC) (Таблица 3.3.1) нейронные сети относятся к числу наиболее точных методов прогнозирования инфляции в российской экономике. Это может быть объяснено тем, что нейронные сети точнее идентифицируют процесс генерации данных согласно универсальной теореме аппроксимации [Cybenko, 1989].

Таблица 3.3.1 – Информационный критерий Акаики

Метод машинного обучения	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
AdaBoost	177.0	171.2	174.5	176.8	176.5	176.7	177.2	175.4	174.7	173.7†	173.6†	173.9
ANN	<b>133.8†</b>	154.4	<b>157.7†</b>	179.8	176.4	<b>160.0†</b>	171.5	168.1	158.4†	174.5†	184.7	165.7
AR(1)	160.3	164.7	168.1	170.9	173.2	174.6	175.5	176.1	176.9	177.7	178.2	178.7
Bagging	176.1	179.3	180.8	180.7	185.5	181.8	182.8	185.3	178.9	180.2	180.6	178.6
BVAR	172.4	193.2	201.5	223.7	201.4	200.8	197.2	208.0	209.9	216.6	205.0	212.6
CARLSON-BG	141.7	148.6	163.1	172.9	174.4	162.3	166.0	<b>154.4</b>	<b>152.6</b>	171.7	182.8	<b>162.8</b>
CARLSON-SA	146.5	151.6	163.8	173.8	175.3	163.6	166.3	154.7	152.8	171.9	184.3	163.0
CatBoost	183.6	187.5	192.6	187.5	187.7	192.8	184.0	180.0	182.9	188.0	182.1	178.0
CLARA-BG	172.8	174.6	174.3	175.6	177.3	178.8	175.5	173.4	174.8	174.0	<b>172.3</b>	170.7
CLARA-CARLSON-BG	150.3	157.1	167.3	172.6	174.7	168.5	169.5	159.2	158.7	172.0	176.0	165.4
CLARA-CARLSON-SA	158.7	162.5	168.8	173.1	175.3	171.1	170.3	161.7	162.0	172.4	177.6	165.9
CLARA-SA	173.0	175.2	175.0	175.8	177.5	179.4	175.5	173.5	174.9	174.6	172.4	170.9
CNN	154.9	159.9	166.4	169.4	177.8	163.7	<b>164.9†</b>	155.6†	160.1	174.0†	186.6	169.8
GRU	164.1	<b>140.5†</b>	172.7	181.9	187.0	171.8	172.1	165.9	160.0	181.1	197.0	168.0
LightGBM	176.2	177.9	180.1	182.7	181.6	180.8	178.3	177.1	179.8	180.7	175.9	169.9
LSTM	159.8	159.9	168.3	179.2	181.6	172.8	173.0	173.3	167.4	181.0	191.0	163.7†
PC-M2	215.9	217.9	219.7	221.0	222.5	223.6	224.6	225.6	226.5	227.0	226.8	226.3
PC-OIL	215.7	217.7	219.4	220.7	222.2	223.3	224.3	225.4	226.3	226.9	226.7	226.2
Random Forest	173.9	177.9	177.3	179.8	184.0	182.4	183.1	180.1	181.8	179.9	179.8	177.3
RNN	158.8	164.9	168.7	<b>168.8†</b>	<b>170.6†</b>	173.2	178.2	169.3	163.9	176.4†	175.5	170.1
SklearnBoost	165.1	168.3	170.8	171.5	174.3	173.0	173.0	173.6	173.8	173.1	172.9	173.0
XGBoost	178.6	183.1	176.8	179.3	180.8	185.3	182.6	178.0	181.6	174.1†	177.8	174.8
MCS-BG	133.8	140.5	157.7	168.8	170.6	160.0	164.9	155.6	158.4	169.5	173.6	163.7
MCS-SA	133.8	140.5	157.7	168.8	170.6	160.0	164.9	155.6	158.4	<b>169.4</b>	173.6	163.7

*Примечание: PC-M2 и PC-OIL отражают результаты для треугольных моделей кривой Филлипса соответственно с лагом денежного агрегата M2 и цены на нефть. «SA», «BG» означает, что веса устанавливаются равными для всех моделей, обратно пропорционально*

среднеквадратической ошибке. «MCS» означает доверительное множество моделей, которое составляется на основе эконометрического теста [Hansen et al., 2011]. Жирным шрифтом отмечены оптимальные модели с точки зрения информационного критерия Акаики. Символом «†» отмечены те методы, которые составляют доверительное множество моделей. Источник: расчеты автора.

Вторым результатом, отраженным в Таблице 3.3.1, является то, что оптимальные модели с точки зрения AIC составляют доверительное множество моделей (MCS) [Hansen et al., 2011] со статистическим уровнем доверия в 95 процентов. Объясняется это тем, что MCS является обобщенной формой AIC. А именно, AIC выбирает одну модель, MCS – предоставляет возможность отобрать несколько оптимальных моделей при заданном уровне статистической значимости. Дополнительная информация по теоретическому обоснованию применения информационного критерия и доверительного множества моделей [Hansen et al., 2011] для отбора наиболее точных из них приведена в параграфе 1.5.

Третий результат, отраженный в Таблице 3.3.1, состоит в том, что сверточные и рекуррентные нейросетевые методы по сравнению с полносвязными нейронными сетями точнее прогнозируют инфляцию на среднесрочном горизонте 4-12 месяцев. В-четвертых, информация, представленная в Таблице 3.3.1, позволяет сделать вывод о том, что на горизонте 8-12 месяцев три метода комбинирования предоставляют более точные прогнозы по сравнению с отдельными моделями.

*Среднеквадратическая ошибка прогноза.* В Таблице 3.3.2 приведена среднеквадратическая ошибка прогноза (RMSE) эталонных моделей, ансамблевых и нейросетевых методов машинного обучения и их комбинаций.

Таблица 3.3.2 – Отношение среднеквадратической ошибки прогноза моделей к среднеквадратической ошибке прогноза авторегрессии первого порядка

Метод машинного обучения	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
AdaBoost	1.23	1.09	1.08	1.08	1.04	1.03	1.02	0.99	0.97	0.95	0.94	0.94
ANN	0.72**	0.88**	0.88	1.12	1.04	0.83	0.95	0.90	0.79	0.96	1.08	0.85***
Bagging	1.22	1.20	1.17	1.13	1.17	1.09	1.10	1.12	1.03	1.03	1.03	1.00
BVAR	1.16	1.43	1.52	1.94	1.42	1.39	1.31	1.49	1.51	1.63	1.40	1.53
CARLSON-BG	0.79	0.82**	0.94	1.02	1.01	0.86	0.89	0.76	0.74	0.93	1.06	0.82*
CARLSON-SA	0.84***	0.85**	0.95	1.04	1.03	0.87	0.89	0.77	0.74	0.93	1.08	0.82*
CatBoost	1.34	1.33	1.36	1.23	1.20	1.26	1.11	1.05	1.08	1.14	1.05	0.99
CLARA-BG	1.17	1.13	1.08	1.06	1.05	1.05	1.00	0.97	0.97	0.96	0.93	0.90
CLARA & CARLSON-BG	0.88**	0.91	0.99	1.02	1.02	0.93	0.93	0.81	0.80	0.93	0.97	0.85
CLARA & CARLSON-SA	0.98	0.97	1.01	1.03	1.03	0.96	0.94	0.84	0.83	0.94	0.99	0.85
CLARA-SA	1.17	1.14	1.09	1.06	1.06	1.06	1.00	0.97	0.98	0.96	0.93	0.91
CNN	0.94*	0.94	0.98	0.98	1.06	0.87	0.88	0.77	0.81	0.96	1.11	0.89
GRU	1.05	0.74	1.06	1.15	1.19	0.97	0.96	0.88	0.81	1.04	1.26	0.87
LightGBM	1.22	1.18	1.16	1.16	1.11	1.08	1.04	1.01	1.04	1.04	0.97	0.90
LSTM	0.99	0.94	1.00	1.11	1.11	0.98	0.97	0.97	0.89	1.04	1.17	0.83
PC-M2	2.00	1.95	1.91	1.87	1.85	1.84	1.85	1.86	1.86	1.85	1.83	1.81
PC-OIL	2.00	1.94	1.90	1.86	1.84	1.84	1.84	1.85	1.85	1.85	1.83	1.81
Random Forest	1.19	1.18	1.12	1.12	1.14	1.10	1.10	1.05	1.06	1.03	1.02	0.98

## Продолжение Таблицы 3.3.2

RNN	0.98	1.00	1.01	0.97*	0.97	0.98	1.03	0.92	0.85	0.98	0.97	0.90
Sklearn Boosting	1.06	1.05	1.03	1.01	1.01	0.98	0.97	0.97	0.96	0.94	0.94	0.93
XGBoost	1.26	1.26	1.11	1.11	1.10	1.14	1.09	1.02	1.06	0.96	1.00	0.95
MCS-BG	0,72**	0,74	0,87	0,97*	0,97	0,83	0,87	0,77	0,79	0,90	0,94	0,82
MCS-SA	0,72**	0,74	0,87	0,97*	0,97	0,83	0,87	0,77	0,79	0,90	0,94	0,82

*Примечание:* Символы «\*», «\*\*», «\*\*\*» означают, что модель точнее авторегрессии первого порядка на 10-, 5-, 1-процентном уровне значимости согласно тесту Дибольда-Мариано. Источник: расчеты автора.

На горизонте 1, 3, 12 месяцев наиболее точные прогнозы получены полносвязными нейронными сетями и комбинацией нейросетевых методов. В частности, на горизонте 1 месяца наибольшее сокращение RMSE относительно точности авторегрессии первого порядка (далее, AR(1)) на 28% наблюдается в модели полносвязных нейронных сетей. Далее по точности прогноза инфляции на горизонте 1 месяца следуют комбинации нейросетевых методов. В свою очередь, рекуррентные нейронные сети предоставляют наиболее точные прогнозы инфляции на горизонте 4 месяцев. Результаты прогнозирования инфляции в России на горизонте от 1, 2, 12 месяцев подтверждают возможности применения предложенных в диссертации моделей, основанных на комбинировании оценок ансамблевых и нейросетевых методов машинного обучения.

В Таблице 3.3.3 представлены RMSE предложенных методов машинного обучения по сравнению с точностью байесовской векторной авторегрессии (далее, BVAR). На горизонте 1, 2 месяцев наиболее точные прогнозы предоставляют полносвязные нейронные сети и комбинации нейросетевых методов, по которым наблюдается сокращение RMSE на 38% и 43% соответственно.

*Таблица 3.3.3 – Отношение среднеквадратической ошибки прогноза моделей к среднеквадратической ошибке прогноза байесовской векторной авторегрессии*

Метод машинного обучения	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
AdaBoost	1.06	0.76	0.71	0.56	0.73	0.74	0.78	0.66	0.64	0.59	0.67	0.62
ANN	0.62**	0.62**	0.58	0.58	0.73	0.60	0.73	0.61	0.53	0.59	0.78	0.56
AR(1)	0.86*	0.70*	0.66	0.52	0.70	0.72	0.76	0.67	0.66	0.61	0.72	0.65
Bagging	1.05	0.84	0.77	0.58	0.82	0.79	0.84	0.75	0.68	0.63	0.74	0.65
CARLSON-BG	0.68***	0.57*	0.62	0.53	0.71	0.62	0.68	0.51	0.49	0.57	0.76	0.54
CARLSON-SA	0.72***	0.59*	0.62	0.54	0.72	0.63	0.68	0.51	0.49	0.57	0.77	0.54
CatBoost	1.15	0.93	0.90	0.64	0.84	0.91	0.85	0.70	0.71	0.70	0.75	0.65
CLARA-BG	1.01	0.79	0.71	0.55	0.74	0.76	0.76	0.65	0.65	0.59	0.66	0.59
CLARA & CARLSON-BG	0.76**	0.64	0.65	0.53	0.72	0.67	0.71	0.54	0.53	0.57	0.70	0.55
CLARA & CARLSON-SA	0.84*	0.68	0.66	0.53	0.72	0.69	0.71	0.56	0.55	0.58	0.71	0.56
CLARA-SA	1.01	0.80	0.72	0.55	0.74	0.77	0.76	0.65	0.65	0.59	0.66	0.59
CNN	0.80***	0.66	0.64	0.51*	0.74	0.63	0.67	0.52	0.54	0.59	0.79	0.59
GRU	0.90	0.52	0.70	0.59	0.84	0.70	0.73	0.59	0.54	0.64	0.90	0.57
LightGBM	1.05	0.83	0.77	0.60	0.78	0.78	0.79	0.68	0.69	0.64	0.69	0.59
LSTM	0.85***	0.66	0.66	0.57	0.78	0.70	0.74	0.65	0.59	0.64	0.84	0.54
PC-M2	1.72	1.36	1.26	0.97	1.30	1.33	1.41	1.25	1.23	1.14	1.31	1.19
PC-OIL	1.72	1.36	1.25	0.96	1.30	1.32	1.40	1.24	1.23	1.14	1.31	1.18
Random Forest	1.02	0.83	0.74	0.58	0.80	0.79	0.84	0.70	0.70	0.63	0.73	0.64

*Продолжение Таблицы 3.3.3*

RNN	0.84**	0.70*	0.66	0.50	0.68	0.71	0.79	0.62	0.56	0.60	0.69	0.59
Sklearn Boosting	0.91	0.73	0.68	0.52	0.71	0.71	0.74	0.65	0.64	0.58	0.67	0.61
XGBoost	1.08	0.88	0.73	0.57	0.77	0.82	0.83	0.69	0.70	0.59	0.71	0.62
MCS-BG	0,62**	0,52*	0,58	0,50	0,68	0,60	0,67	0,52	0,52	0,55	0,67	0,54
MCS-SA	0,62**	0,52*	0,58	0,50	0,68	0,60	0,67	0,52	0,52	0,55	0,67	0,54

*Примечание: Символы «\*», «\*\*», «\*\*\*» означают, что модель точнее авторегрессии первого порядка на 10-, 5-, 1-процентном уровне значимости согласно тесту Дибольда-Мариано. Источник: расчеты автора.*

Предложенные в диссертации сверточные и рекуррентные нейронные сети также прогнозируют инфляцию точнее, чем BVAR, на горизонте 1, 2, 4 месяцев. В частности, сверточные нейронные сети по сравнению с BVAR на 20% и 49% точнее прогнозируют инфляцию на горизонте 1 и 4 месяцев. Данный результат может быть объяснен тем, что операции свертки позволяют выявить локальные зависимости, существующие между инфляцией и ее факторами. В свою очередь, сокращение RMSE рекуррентными нейронными сетями на горизонте 1 и 2 месяцев составляет 16% и 30% соответственно<sup>53</sup>. На горизонте от 5 до 12 месяцев ансамблевые и нейросетевые методы статистически незначимо превышают точность BVAR. Это согласуется с исследованиями, в которых отмечается, что более сложные методы не всегда превосходят базовые модели по точности прогноза инфляции [Faust, Wright, 2013; Styrim, 2019; Joseph et al., 2022].

Помимо эмпирически зарекомендованных бенчмарков (авторегрессии, байесовские векторные авторегрессии) мы также проводим сравнение точности ансамблевых и нейросетевых методов машинного обучения относительно кривых Филлипса [Картаев, Беседовская, 2023]. Первая треугольная форма кривой Филлипса включает 24 лага темпов прироста общего уровня цен, уровня безработицы, денежного агрегата M2. Результаты сравнения точностей методов машинного обучения и данной треугольной формы кривой Филлипса представлены в Таблице 3.3.4.

Согласно данным, приведенным в Таблице 3.3.4, по точности прогноза инфляции на горизонте от 1 до 12 месяцев предложенные в настоящей диссертации ансамблевые и нейросетевые методы машинного обучения статистически значимо превосходят треугольную кривую Филлипса. На горизонте 1, 3, 6 месяцев наиболее точный прогноз предоставляет полносвязная нейронная сеть. Сверточные и рекуррентные нейронные сети точнее прогнозируют инфляцию на горизонте 2, 4, 5, 7 месяцев.

<sup>53</sup> В работе [Джункеев, 2022] при прогнозировании циклической безработицы на статистических данных по России за период с января 2002 г. по декабрь 2020 г. получено, что средняя абсолютная ошибка прогноза моделей рекуррентных нейронных сетей по сравнению с точностью прогноза закона Оукена на горизонте 1 месяца сокращается более чем в 2 раза – на 56%.

Таблица 3.3.4 – Отношение среднеквадратичной ошибки методов машинного обучения к среднеквадратической ошибке треугольной кривой Филлипса с денежным агрегатом М2

Метод машинного обучения	Горизонт прогнозирования (месяц)													
	8	9	10	11	12	8	9	10	11	12	8	9	10	11
AdaBoost	0.6***	0.6***	0.6***	0.6**	0.6**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
ANN	0.4***	0.5***	0.5*	0.6**	0.6**	0.5**	0.5**	0.5**	0.4**	0.5**	0.6**	0.5**	0.6**	0.5**
AR(1)	0.5***	0.5***	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.6**	0.6**	0.6**	0.6**
BVAR	0.6***	0.7*	0.8	1.0	0.8**	0.8	0.7	0.8**	0.8**	0.9	0.8	0.8	0.8	0.8
CARLSON-BG	0.4***	0.4***	0.5**	0.6	0.6**	0.5**	0.5**	0.4**	0.4**	0.5**	0.6**	0.5**	0.6**	0.5**
CARLSON-SA	0.4***	0.4***	0.5**	0.6	0.6**	0.5	0.5**	0.4**	0.4**	0.5**	0.6**	0.5**	0.6**	0.5**
CatBoost	0.7**	0.7**	0.7*	0.7**	0.7*	0.7*	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**
CNN	0.5***	0.5***	0.5***	0.5	0.6**	0.5**	0.5**	0.4**	0.4**	0.5**	0.6**	0.5**	0.6**	0.5**
GRU	0.5***	0.4***	0.6**	0.6*	0.6**	0.5**	0.5**	0.5**	0.4**	0.6**	0.7**	0.5**	0.6**	0.5**
LightGBM	0.6***	0.6***	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**
LSTM	0.5***	0.5***	0.5**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.6**	0.6**	0.6**	0.6**	0.5**
PC-OIL	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Random Forest	0.6***	0.6***	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.5**
RNN	0.5***	0.5***	0.5**	0.5**	0.5**	0.5**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
Sklearn Boosting	0.5***	0.5***	0.5**	0.5**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
XGBoost	0.6***	0.7**	0.6**	0.6**	0.6**	0.6*	0.6**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**
MCS-BG	0.4***	0.4***	0.5***	0.5**	0.5**	0.5**	0.5**	0.4**	0.4**	0.5**	0.5**	0.5**	0.5**	0.5**
MCS-SA	0.4***	0.4***	0.5***	0.5**	0.5**	0.5**	0.5**	0.4**	0.4**	0.5**	0.5**	0.5**	0.5**	0.5**

Примечание: Символы «\*», «\*\*», «\*\*\*» означают, что модель точнее авторегрессии первого порядка на 10-, 5-, 1-процентном уровне значимости согласно тесту Дибольда-Мариано. Источник: расчеты автора.

Один из ключевых результатов настоящей диссертации приведен в Таблице 3.3.4. На горизонте от 8 до 12 месяцев наиболее точные результаты получены моделями, которые комбинируют прогнозы ансамблевых и нейросетевых методов машинного обучения. В частности, на горизонте 11 месяцев наибольшее сокращение RMSE – на 49,37% – относительно кривой Филлипса с денежным агрегатом М2 получено в модели комбинирования ансамблевых методов машинного обучения. На горизонте от 7 до 9 месяцев, а также 12 месяцев прогнозные преимущества демонстрируют модели, которые комбинируют прогнозы нейросетевых методов машинного обучения: сокращение среднеквадратичной ошибки составляет 58,94%, 60,28%, 49,91%, 54,78%.

Вторая эталонная модель кривой Филлипса включает 24 лага темпов прироста общего уровня цен, уровня безработицы, цен на нефть марки Brent. Результаты сравнения точностей методов машинного обучения и данной треугольной формы кривой Филлипса представлены в таблице 3.3.5.

Таблица 3.3.5 – Отношение среднеквадратической ошибки моделей к среднеквадратической ошибке кривой Филлипса с ценой на нефть марки Brent

Метод машинного обучения	Горизонт прогнозирования (месяц)											
	1	2	3	4	5	6	7	8	9	10	11	12
AdaBoost	0.6	0.6***	0.6***	0.6**	0.6**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**
ANN	0.4	0.5***	0.5*	0.6**	0.6**	0.5**	0.5**	0.5**	0.4**	0.5**	0.6**	0.5**
AR(1)	0.5	0.5***	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.6**	0.6**
BVAR	0.6	0.7*	0.8	1.0	0.8**	0.8	0.7	0.8**	0.8**	0.9	0.8	0.8
CARLSON-BG	0.4	0.4***	0.5**	0.6	0.6**	0.5**	0.5**	0.4**	0.4**	0.5**	0.6**	0.5**
CLARA-BG	0.6	0.6***	0.6**	0.6	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
CLARA & CARLSON-BG	0.4	0.5***	0.5**	0.6	0.6**	0.5**	0.5**	0.4**	0.4**	0.5**	0.5**	0.5**
CLARA & CARLSON-SA	0.5	0.5***	0.5**	0.6	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
CLARA-SA	0.6	0.6***	0.6**	0.6	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
CNN	0.5	0.5***	0.5***	0.5	0.6**	0.5**	0.5**	0.4**	0.4**	0.5**	0.6**	0.5**
DFM-3	0.3	0.3***	0.3***	0.3	0.3**	0.7**	0.3**	0.5**	0.9**	0.6**	0.6*	0.8**
GRU	0.5	0.4***	0.6**	0.6*	0.6**	0.5**	0.5**	0.5**	0.4**	0.6**	0.7**	0.5**
LightGBM	0.6	0.6***	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.5**	0.5**
LSTM	0.5	0.5***	0.5**	0.6**	0.6**	0.5**	0.5**	0.5**	0.5**	0.6**	0.6**	0.5**
PC-OIL	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Random Forest	0.6	0.6***	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.6**	0.5**
RNN	0.5	0.5***	0.5**	0.5**	0.5**	0.5**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**
Sklearn Boosting	0.5	0.5***	0.5**	0.5**	0.6**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**	0.5**
XGBoost	0.6	0.7**	0.6**	0.6**	0.6**	0.6*	0.6**	0.6**	0.6**	0.5**	0.5**	0.5**
MCS-BG	0,4***	0,4***	0,5***	0,5**	0,5**	0,5**	0,5**	0,4**	0,4**	0,5**	0,5**	0,5**
MCS-SA	0,4***	0,4***	0,5***	0,5**	0,5**	0,5**	0,5**	0,4**	0,4**	0,5**	0,5**	0,5**

Примечание: Символы «\*», «\*\*», «\*\*\*» означают, что модель точнее авторегрессии первого порядка на 10-, 5-, 1-процентном уровне значимости согласно тесту Дибольда-Мариано. Источник: расчеты автора.

Результаты, содержащиеся в таблице 3.3.5, аналогичны тем, что представлены в Таблице 3.3.4: 1) на горизонте 1, 3, 6 месяцев наиболее точные прогнозы предоставляет полносвязная нейронная сеть; 2) на горизонте 2 месяцев – модель управляемого рекуррентного блока; 3) на горизонте 4 и 5 месяцев – рекуррентная нейронная сеть; 4) на горизонте 7 месяцев – сверточная нейронная сеть; 5) на горизонте от 8 до 12 месяцев – комбинации ансамблевых и нейросетевых методов машинного обучения. Таким образом, результаты, приведенные в Таблицах 3.3.4 и 3.3.5, подтверждают то, что по сравнению с кривой Филлипса методы машинного обучения точнее прогнозируют темпы роста ИПЦ г/г в России.

Рисунки А1-А9 Приложения иллюстрируют прогнозы инфляции тренировочного множества. Можно видеть, что модели градиентного бустинга и нейронных сетей частично могут выявить повышение инфляции в I квартале 2015 г. Прогнозы инфляции тестового множества представлены на Рисунках А10-А19 Приложения. Более точные прогнозы инфляции с помощью ANN на горизонте 1, 6 месяцев обусловлены тем, что данная модель

точнее идентифицирует повышение инфляции в I квартале 2022 г. по сравнению с другими методами машинного обучения.

*Влияние пересмотров статистических данных на точность моделей.* Обратимся к результатам прогнозирования на основе предварительных и пересмотренных данных, представленным на Рисунке 3.3.1.




Рисунок 3.3.1 – Среднеквадратическая ошибка прогноза моделей на предварительных и пересмотренных данных. Источник: расчеты автора

По сравнению с [Mamedli, Shibitov, 2021] в настоящей работе на винтажных данных составляются прогнозы инфляции не только с помощью градиентного бустинга XGBoost и Sklearn Boosting, полносвязной нейронной сети, но также и более продвинутых моделей

градиентного бустинга CatBoost и LightGBM, сверточных и рекуррентных нейронных сетей.

Согласно Рисунку 3.3.1 наблюдается небольшое изменение точности моделей в результате пересмотра статистических данных с ноября 2020 г. по сентябрь 2021 г. Среднеквадратическая ошибка прогноза повышается в нейросетевых методах: ANN на горизонте 2 кварталов, GRU – 4 кварталов, LSTM – 3 кварталов (Таблица 3.3.6).

Таблица 3.3.6 – Разность между среднеквадратической ошибкой прогноза на пересмотренных данных за сентябрь 2021 г. и среднеквадратической ошибкой прогноза на предварительных данных за ноябрь 2020 г.

Модель	Горизонт прогнозирования (квартал)			
	1	2	3	4
AdaBoost	0.00000	0.00000	0.00000	0.00000
ANN	0.00000	+0.00159	0.00000	0.00000
AR(1)	0.00000	0.00000	0.00000	0.00000
CatBoost	0.00000	0.00000	0.00000	0.00000
CNN	-0.00046	0.00000	0.00000	0.00000
GRU	0.00000	-0.00001	-0.00007	+0.00001
LightGBM	0.00000	0.00000	0.00000	0.00000
LSTM	-0.00003	0.00000	+0.00002	-0.00005
Random Forest	0.00000	0.00000	0.00000	0.00000
RNN	0.00000	0.00000	0.00000	0.00000
XGBoost	0.00000	0.00000	0.00000	0.00000

Примечание: зеленым (красным) цветом отмечено снижение (повышение) среднеквадратической ошибки в результате пересмотра статистических данных. Источник: расчеты автора.

В научной литературе отмечается, что ошибки измерения могут быть причиной эндогенности эконометрических моделей [Dougherty, 2011, С. 306-309; Verbeek, 2017, С. 144-146; Woolridge, 2018, С. 308-312; Картаев, 2019, С. 222; Stock, Watson, 2020, С. 336-339].

Шаг 1. Предположим, что взаимосвязь между объясняемой переменной  $i$ -го наблюдения  $y_i$  и объясняющей переменной  $x_i^*$  определяется моделью  $y_i = \beta_0 + \beta_1 x_i^* + e_i$ , где  $e_i$  – ошибки регрессии, которые не связаны с объясняющей переменной  $cov(x_i^*, e_i) = 0$ .

Шаг 2. Предположим, что значения объясняющей переменной могут пересматриваться, так как предварительная информация по ней публикуется с ошибками измерения. Следовательно, мы наблюдаем  $x_i = x_i^* + u_i$ , где  $u_i$  – ошибки измерения, которые не связаны с ошибками регрессии  $cov(u_i, e_i) = 0$ .

Шаг 3. Оцениваем модель  $y_i = \beta_0 + \beta_1 x_i + e_i = \beta_0 + \beta_1 (x_i^* - u_i) + e_i = \beta_0 + \beta_1 x_i^* - \beta_1 u_i + e_i = \beta_0 + \beta_1 x_i^* + v_i$ , где  $v_i = -\beta_1 u_i + e_i$  является регрессионной ошибкой.

Шаг 4. Оцениваем сходимость оценок по вероятности

$$\begin{aligned} \widehat{\beta}_1 &\xrightarrow{p} \beta_1 + \frac{cov(x_i, v_i)}{var(x_i)} = \beta_1 + \frac{cov(x_i^* + u_i, -\beta_1 u_i + e_i)}{var(x_i^* + u_i)} = \beta_1 + \\ &\frac{cov(x_i^*, -\beta_1 u_i) + cov(x_i^*, u_i) + cov(u_i, -\beta_1 u_i) + cov(u_i, e_i)}{var(x_i^*) + var(u_i)} = \beta_1 + \frac{-\beta_1 \cdot 0 - \beta_1 cov(u_i, u_i)}{var(x_i^*) + var(u_i)} = \beta_1 + \frac{-\beta_1 var(u_i)}{var(x_i^*) + var(u_i)} = \\ &\beta_1 \frac{var(x_i^*)}{var(x_i^*) + var(u_i)}, \text{ где } \left| \frac{var(x_i^*)}{var(x_i^*) + var(u_i)} \right| < 1. \end{aligned}$$

Следовательно, ошибки измерения приводят к несостоятельности оценок и смещению оценок параметров моделей. Несмотря на простоту эконометрического уравнения вышеприведенные аналитические выводы подтверждаются результатами прогнозирования ВВП России. В работе [Божечкова, Джункеев, 2024] получено, что RMSE авторегрессии первого порядка выше на пересмотренных данных по сравнению с предварительной статистикой. Таким образом, подтверждается важность учета пересмотров информации при оценке моделей и прогнозировании макроэкономических показателей<sup>54</sup>.

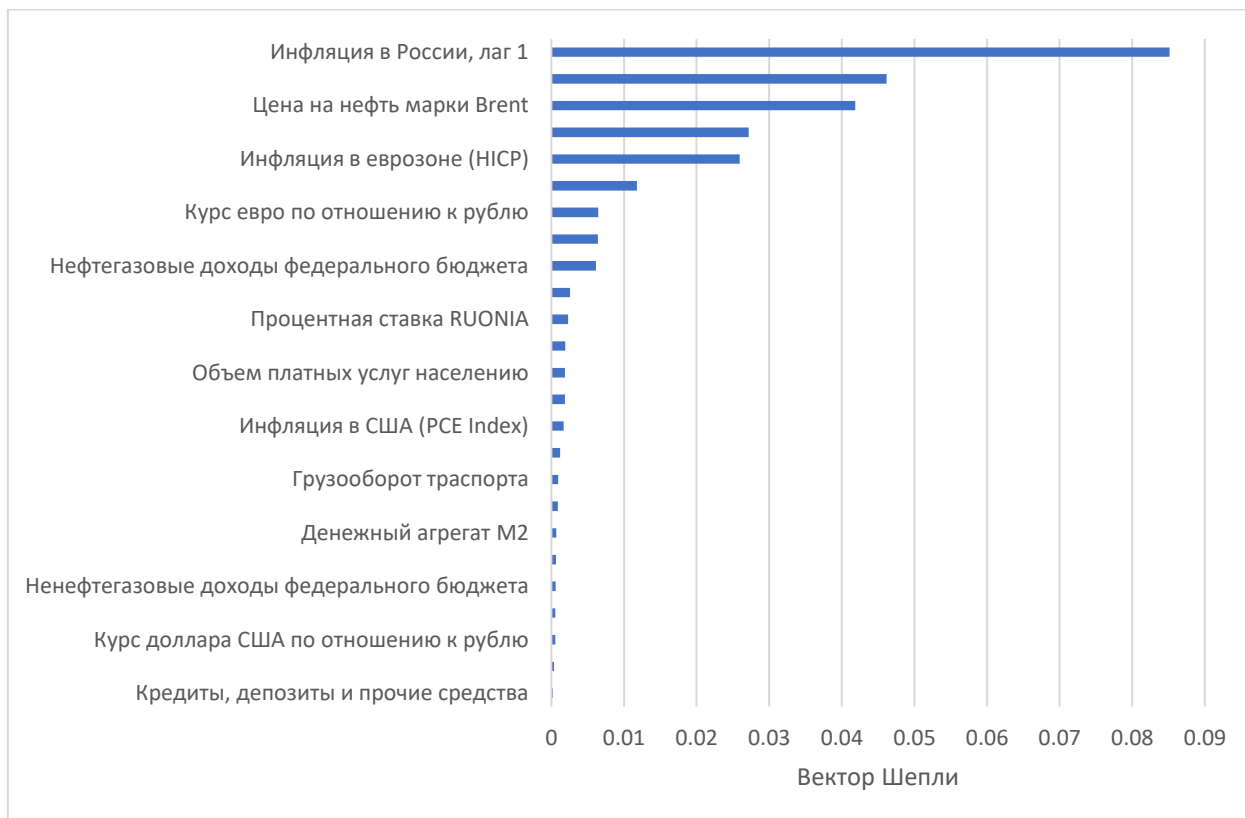
*Вектор Шепли и коэффициент важности переменных.* Перейдем к интерпретации результатов наиболее точных методов машинного обучения (Sklearn Gradient Boosting, полносвязные нейронные сети ANN<sup>55</sup>) вектором Шепли (см. уравнение 3.2.2). Графическая иллюстрация вектора Шепли для Sklearn Gradient Boosting и ANN представлена на Рисунке 3.3.2 и Рисунке 3.3.3.

Большую долю в прогнозе темпов роста ИПЦ модели Sklearn Gradient Boosting имеет первый лаг инфляции, характеризующий адаптивные инфляционные ожидания. Напомним, что тестовый период составляет август 2019 г. – апрель 2023 г., который включает

<sup>54</sup> В свою очередь, на основе метода инструментальных переменных получено, что человеческий капитал является значимым фактором темпов роста ВВП России [Божечкова и др., 2024].

<sup>55</sup> Для Sklearn Gradient Boosting применяется метод TreeExplainer, а для ANN – DeepExplainer. TreeExplainer / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/generated/shap.TreeExplainer.html> (дата обращения: 05.04.2024). DeepExplainer / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/generated/shap.DeepExplainer.html> (дата обращения: 06.04.2024)

пандемический шок с марта 2020 г., рост цен на сырьевые товары и ослабление валютного курса рубля в I квартале 2022 г. Следовательно нестабильность инфляционных ожиданий может объясняться последствиями шоков, которые произошли в I квартале 2020 г. и I квартале 2022 г.




*Рисунок 3.3.2 – Вектор Шепли для модели градиентного бустинга Sklearn. Источник: расчеты автора*

Второй категорией показателей, которые повышают точность прогноза инфляции в российской экономике, являются цены на сырьевые и продовольственные товары: индекс цен ФАО, цены на нефть и природный газ. Это может объясняться тем, что ужесточение санкций в I квартале 2022 г. привело к повышению цен на сырьевые товары. Рост цен на сырьевые товары повышает издержки производителей и уровень инфляции.

Учет оборота розничной торговли пищевых продуктов, непродовольственных товаров повышает точность прогнозирования инфляции в российской экономике. Пандемический шок привел к задержке поставок товаров. Это вызвало превышение спроса над предложением товаров, что привело к повышению инфляции.

Более точный прогноз инфляции в России также возможен если учитывать инфляцию в еврозоне и валютный курс евро к рублю. Это может объясняться эффектом переноса

валютного курса в цены, а также ограничением импорта российской нефти и природного газа в страны еврозоны<sup>56</sup>.



*Рисунок 3.3.3 – Вектор Шепли для модели полносвязной нейронной сети. Источник: расчеты автора*

Таким образом, результаты настоящей работы согласуются с исследованиями о значимом влиянии валютного курса на цены [Трунин, Пономарев, 2014; Синяков и др., 2019].

Согласно вектору Шепли для полносвязной нейронной сети (см. Рисунок 3.3.3), наблюдаются следующие закономерности, которые связаны со значимостью макроэкономических факторов в получении более точных прогнозов инфляции в России.

Темп прироста численности официально зарегистрированных безработных позволяет получить наиболее точные прогнозы инфляции, что согласуется с предпосылками кривой Филлипса: более высокий уровень безработицы ассоциируется с меньшим темпом роста общего уровня цен. [Blanchard, Bernanke, 2023] также получили, что показатели рынка труда являются важными объясняющими факторами инфляции в период пандемии. Так, в

<sup>56</sup> Косвенное влияние глобальной мировой экономики на инфляцию в России может характеризоваться следующим трансмиссионным механизмом: рост импорта обуславливает сокращение спроса на товары внутренних фирм, что также приводит к изменению уровня безработицы и инфляции. Так, в работе [Джункеев, 2023] на основе системного обобщенного метода моментов выявлено, что увеличение объема импорта ассоциируется со снижением уровня занятости в регионах России за период 2005-2019 гг.

качестве показателя рынка труда США выступает отношение уровня вакансий к уровню безработицы. На статистических данных по США за период с I квартала 2021 г. по I квартал 2023 г. выявлено, что шок индикатора активности на рынке труда приводит к статистически значимому росту цен, который сохраняется в течение 16 кварталов. Таким образом, можно полагать, что достижению ценовой стабильности также способствует регулирование ситуации на рынке труда<sup>57</sup>.

Второй группой значимых макроэкономических показателей для получения наиболее точных прогнозов инфляции являются нефтегазовые и ненефтегазовые доходы федерального бюджета. Действительно, стимулирующая бюджетно-налоговая политика в форме роста государственных расходов, трансфертов домашним компаниям и частным компаниям приводит к росту агрегированного спроса, что также способствует повышению инфляции.

Помимо учета характеристик бюджетно-налоговой политики более точные прогнозы инфляции в российской экономике дает использование показателей, которые зависят от денежно-кредитной политики: денежный агрегат M2, доходность облигаций федерального займа с 3-месячным сроком до погашения. Стимулирующая денежно-кредитная политика в форме роста объема денежной массы приводит к повышению инфляции через рост агрегированного спроса. Доходность краткосрочных государственных облигаций отражает ожидания экономических агентов относительно денежно-кредитной политики и вероятности наступления рецессий [Дробышевский, 1999а, 1999б].

Повышение точности прогнозов инфляции за счет учета объема платных услуг населению может быть обусловлено несоответствием между агрегированным спросом и предложением, которое наблюдалось при пандемическом шоке. В частности, улучшение эпидемиологической ситуации позволило снять ограничения на социальное дистанцирование, что повысило спрос на услуги.

Важность учета темпов роста цен в США при прогнозе инфляции в России может объясняться тем, что цикл повышения ключевой ставки ФРС (наблюдавшийся на прогнозном, тестовом периоде) ассоциируется с ужесточением условий на мировых финансовых рынках [Miranda-Agrippino, Rey, 2020], которое отражается на состоянии финансовой системы и уровне инфляции в малой экономике.

---

<sup>57</sup> В работе [Джункеев, 2021] на статистических данных по России за период 2003-2019 гг. выявлено, что технологически более развитые регионы характеризуются меньшим уровнем безработицы. Также показано, что с улучшением демографической ситуации в России повышается занятость в ее регионах.

Следует отметить, что учет не только нефтегазовых, но и ненафтогазовых доходов федерального бюджета сказывается на повышении точности прогноза инфляции в России. Это может объясняться косвенным каналом влияния мировой экономики на инфляцию в малой экономике. Так, страны еврозоны вводили прямые ограничения на экспорт и повышали импортные тарифы на сельскохозяйственную продукцию, произведенную в России, что также отразилось на инфляции в российской экономике.




Рисунок 3.3.4 – Важность переменной согласно Sklearn Gradient Boosting. Источник: расчеты автора

Помимо вектора Шепли, для Sklearn Gradient Boosting мы используем коэффициент важности переменной (feature importance<sup>58</sup>) при интерпретации результатов данной ансамблевой модели<sup>59</sup> (Рисунок 3.3.4).

Объясняющие переменные с наибольшим коэффициентом важности (Рисунок 3.3.4) аналогичны тем, которые были определены по значениям вектора Шепли (Рисунок 3.3.2). К числу значимых факторов инфляции в российской экономике относятся мировые цены

<sup>58</sup> Feature importance with a forest of trees / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/auto\\_examples/ensemble/plot\\_forest\\_importances.html](https://scikit-learn.org/stable/auto_examples/ensemble/plot_forest_importances.html) (дата обращения: 10.04.2024)

<sup>59</sup> Применимость алгоритмов градиентного бустинга в идентификации наиболее релевантных предикторов подтверждает [Zeng, 2017] на основе экспериментов Монте-Карло, а также апробирования градиентного бустинга в прогнозировании макроэкономических показателей, в том числе инфляции, 12 стран еврозоны за период с I квартал 1970 г. по IV квартал 2011 г. Также [Kohlscheen, 2022] применил атрибут моделей случайного леса «важность переменных» в идентификации объясняющих факторов инфляции 20 развитых странах за период 2000-2021 гг.

на сырьевые товары, первый лаг темпов роста ИПЦ в России, индекс продовольственных цен ФАО, оборот торговли продовольственными и непродовольственными товарами, темп роста ИПЦ в еврозоне. Таким образом, для получения более точных прогнозов инфляции в Российской Федерации ансамблевыми методами необходимо учитывать цены на сырьевые товары, внутри- и межстрановые инфляционные ожидания, потребительский спрос.

## Заключение

Настоящая диссертация является одной из первых работ, в которых инфляция в российской экономике прогнозируется с помощью сверточных и рекуррентных нейронных сетей; модели рекуррентного блока; адаптивного, упорядоченного, поправочного градиентных бустингов; модели долгой краткосрочной памяти. Помимо методологических аспектов прогнозирования инфляции в Российской Федерации отдельное внимание уделяется составлению выборки, которое опирается на описанные в диссертации теоретические механизмы влияния макроэкономических показателей на инфляцию.

Комплексная систематизация теоретических и эмпирических исследований, посвященных прогнозированию инфляции, а также апробация предложенных в диссертации ансамблевых и нейросетевых методов машинного обучения на российских данных позволили прийти к следующим результатам и выводам.

1. На основе обзора эмпирических исследований, посвященных прогнозированию инфляции на основе методов машинного обучения, составлены четыре группы основных методов оценки будущей динамики цен: 1) эконометрические; 2) байесовские; 3) ансамблевые; 4) нейросетевые. Данная систематизация эмпирических исследований позволила выявить возможности применения предложенных в диссертации методов машинного обучения, которые впервые апробированы в задаче прогнозирования инфляции в России. К числу данных методов относятся сверточные, рекуррентные нейронные сети; упорядоченный, адаптивный, поправочный градиентные бустинги; модель управляемого рекуррентного блока; модель долгой краткосрочной памяти.

2. Помимо инструментального подхода к прогнозированию инфляции в работе уделяется особое внимание составлению выборки, которая позволяет апробировать модифицированные ансамблевые и нейросетевые методы машинного обучения. В частности, для сверточных и рекуррентных нейронных сетей предложен алгоритм, результатом которого является преобразование двумерной матрицы размерности (число наблюдений; количество переменных) в трехмерную матрицу (число подвыборок; количество наблюдений, на которых оцениваются нейронные сети; количество переменных). Для технической реализации модифицированных ансамблевых

методов машинного обучения разработан алгоритм, который позволяет преобразовать исходную матрицу размерности (количество наблюдений; количество макроэкономических факторов инфляции) в блочную матрицу большей размерности, определяемой количеством наблюдений, умноженным на количество макроэкономических факторов инфляции, и длиной временного ряда, на основе которого оцениваются ансамблевые методы машинного обучения.

3. Составлена теоретически обоснованная выборка, которая состоит из четырех групп макроэкономических факторов инфляции, характеризуемых показателями рынка труда, производственного сектора, финансов в национальной и мировой экономике, а также инфляционными ожиданиями экономических агентов. Систематизация теоретических исследований позволила: (1) комплексно подойти к изучению трансмиссионных механизмов влияния макроэкономических показателей на инфляцию; (2) содержательно интерпретировать результаты, полученные ансамблевыми и нейросетевыми методами машинного обучения.

4. Помимо использования оперативной макроэкономической информации Федеральной службы государственной статистики в настоящей диссертации инфляция в России прогнозируется на винтажных данных, которые доступны на момент оценки моделей. Подход к прогнозированию инфляции на винтажных данных позволяет оценить изменение точности моделей при пересмотрах статистической информации. Выявлено, что пересмотры статистических данных приводят к снижению точности прогнозирования полносвязных нейронных сетей. На краткосрочном горизонте наблюдается снижение, а на среднесрочном горизонте – повышение среднеквадратичной ошибки прогноза рекуррентных нейронных сетей. Ансамблевые методы по сравнению с нейронными сетями демонстрируют более высокую устойчивость к пересмотрам статистической информации.

5. Выявлено преимущество разработанных моделей комбинирования модифицированных ансамблевых и нейросетевых методов машинного обучения перед эконометрическим инструментарием с точки зрения среднеквадратических ошибок прогноза, информационного критерия Акаики, теста Дибольда-Мариано, эконометрического теста на доверительное множество моделей. В частности, при выборе авторегрессии первого порядка в качестве эталонной модели получены следующие результаты. Во-первых, на горизонте 1, 3, 6 месяцев наиболее точные прогнозы получены полносвязными нейронными сетями. Во-вторых, на горизонте 2, 4, 5 месяцев наименьшая среднеквадратическую ошибку дают рекуррентные нейронные сети и управляемый рекуррентный блок. В-третьих, на горизонте 7, 8 месяцев прогнозное преимущество

демонстрируют сверточные нейронные сети. В то же время, ансамблевые методы не во всех случаях превосходят точность авторегрессии первого порядка. Это согласуется с выводами исследований, в которых отмечается, что более сложные методы не всегда точнее прогнозируют инфляцию по сравнению с базовыми моделями. Результаты прогнозирования инфляции в российской экономике на горизонте от 9 до 12 месяцев подтверждают возможности применения предложенных в диссертации моделей, которые комбинируют результаты ансамблевых и нейросетевых методов машинного обучения. В частности, на горизонте 9, 10, 12 месяцев прогнозируемое преимущество перед авторегрессией первого порядка выявлено в модели, комбинирующей оценки нейросетевых методов машинного обучения, часть которых ранее не использовалась для прогнозирования инфляции в России. На горизонте 8 месяцев наибольшее сокращение среднеквадратичной ошибки относительности точности авторегрессии первого порядка выявлено в модели комбинирования ансамблевых методов машинного обучения, часть которых впервые апробируется в задаче прогнозирования инфляции в российской экономике. При выборе байесовской векторной авторегрессии в качестве эталонной модели получены следующие результаты. Во-первых, на горизонте 1, 12 месяцев наиболее точные прогнозы предоставляет модель долгой краткосрочной памяти. Во-вторых, полносвязная нейронная сеть демонстрирует прогнозируемое преимущество на горизонте от 1 до 4 месяцев, от 6 до 10 месяцев. В-третьих, на горизонте 5 месяцев наибольшее сокращение среднеквадратичной ошибки по сравнению с байесовской векторной авторегрессией получено в модели сверточных нейронных сетей. В-четвертых, наряду с нейронными сетями более точные прогнозы по сравнению с байесовской векторной авторегрессией получены ансамблевыми методами машинного обучения. При выборе кривой Филлипса (24 лага темпов прироста общего уровня цен, уровня безработицы, денежного агрегата, цен на нефть) в качестве эталонной модели выявлены следующие закономерности. Во-первых, на горизонте 1, 3, 6 месяцев прогнозируемое преимущество демонстрирует полносвязная нейронная сеть. В-вторых, модифицированные нейронные сети предоставляют наиболее точные прогнозы инфляции на следующих горизонтах: 2 месяца – модель управляемого рекуррентного блока; на горизонте 4 и 5 месяцев – модель рекуррентных нейронных сетей; на горизонте 7 месяцев – модель сверточных нейронных сетей.

6. На основе вектора Шепли определены макроэкономические показатели, учет которых приводит к более точным прогнозам инфляции в России методами машинного обучения. Результаты модели градиентного бустинга указывают на адаптивные инфляционные ожидания, так как согласно вектору Шепли при прогнозе инфляции в

Российской Федерации наибольшая доля приходится на ее первый лаг. Вторая группа макроэкономических факторов, которые способствуют получению более точных прогнозов инфляции в России, являются общие уровни цен в еврозоне и США, цены на нефть марки Brent, индекс продовольственных цен ФАО, официальные курсы евро и доллара США к рублю, что показывает важность учета показателей глобальной экономики при оценке темпов роста цен в Российской Федерации. Результаты вектора Шепли для полносвязной нейронной сети указывают на то, что для составления более точных прогнозов инфляции необходимо учитывать показатели безработицы. Далее, следуют цены на энергоносители (природный газ, нефть), что может отражать значимость эффекта переноса цен на сырьевые товары в инфляцию в российской экономике. Получению более точных прогнозов инфляции в России способствует использование показателей денежно-кредитной и бюджетно-налоговой политики, которые влияют на общий уровень цен через рост агрегированного спроса, а именно: нефтегазовых и ненефтегазовых доходов государственного бюджета, уровня внешнего долга, государственных расходов и объема денежной массы.

## Список использованных источников

### Электронные ресурсы

1. Sklearn Min Max Scaler / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html> (дата обращения: 06.02.2024).
2. Краткосрочные экономические показатели Российской Федерации / Росстат: сайт. URL: <https://rosstat.gov.ru/compendium/document/50802> (дата обращения: 15.01.2024).
3. Краткая информация об исполнении федерального бюджета / Министерство финансов Российской Федерации: сайт. URL: <https://minfin.gov.ru/ru/statistics/fedbud/execute/> (дата обращения: 17.01.2024).
4. Государственный внешний и внутренний долг / Министерство финансов Российской Федерации: сайт. URL: [https://minfin.gov.ru/ru/statistics/gov\\_debt/external\\_internal\\_debt/](https://minfin.gov.ru/ru/statistics/gov_debt/external_internal_debt/) (дата обращения: 17.01.2024).
5. Денежная масса (национальное определение) / Банк России: сайт. URL: <https://www.cbr.ru/statistics/ms/> (дата обращения: 21.01.2024).
6. Ruble Overnight Index Average / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/ruonia/](https://www.cbr.ru/hd_base/ruonia/) (дата обращения: 21.01.2024).
7. Показатели ставок межбанковского кредитного рынка группы МІАСR / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/mkr/mkr\\_base/](https://www.cbr.ru/hd_base/mkr/mkr_base/) (дата обращения: 21.01.2024).
8. Кривая бескупонной доходности государственных облигаций / Банк России: сайт. URL: [https://www.cbr.ru/hd\\_base/zcyc\\_params/](https://www.cbr.ru/hd_base/zcyc_params/) (дата обращения: 21.01.2024).
9. Crude Oil Prices: Brent – Europe / Federal Reserve Bank of St. Louis: site. URL: <https://fred.stlouisfed.org/series/DCOILBRETEU> (дата обращения: 22.01.2024).
10. Global price of Natural gas / Federal Reserve Bank of St. Louis: site. URL: <https://fred.stlouisfed.org/series/PNGASEUUSDM> (дата обращения: 22.01.2024).
11. Personal Consumption Expenditures: Chain-type Price Index / Federal Reserve Bank of St. Louis: site. URL: <https://fred.stlouisfed.org/series/PCEPI> (дата обращения: 22.01.2024).

12. HICP – Overall Euro area / European Central Bank: site. URL: <https://data.ecb.europa.eu/data/datasets/ICP/ICP.M.U2.Y.000000.3.INX> (дата обращения: 04.02.2024).
13. FAO Food Price Inde / Food and Agriculture Organization of the United States: site. URL: <https://www.fao.org/worldfoodsituation/foodpricesindex/en/> (дата обращения: 04.02.2024).
14. Train test split / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.train\\_test\\_split.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.train_test_split.html) (дата обращения: 06.02.2024).
15. Time series data loading / Keras: site. URL: <https://keras.io/api/preprocessing/timeseries/#timeseriesdatasetfromarray-function> (дата обращения: 08.02.2024).
16. Time Series Generator / TensorFlow: site. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/sequence/TimeSeriesGenerator](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/sequence/TimeSeriesGenerator) (дата обращения: 10.02.2024).
17. AdaBoostRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.AdaBoostRegressor.html> (дата обращения: 21.02.2024).
18. BaggingRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.BaggingRegressor.html> (дата обращения: 21.02.2024).
19. CatBoostRegressor / CatBoost: site. URL: [https://catboost.ai/en/docs/concepts/python-reference\\_catboostregressor](https://catboost.ai/en/docs/concepts/python-reference_catboostregressor) (дата обращения: 22.02.2024).
20. LGBMRegressor / LightGBM: site. URL: <https://lightgbm.readthedocs.io/en/latest/pythonapi/lightgbm.LGBMRegressor.html> (дата обращения: 22.02.2024).
21. RandomForestRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html> (дата обращения: 22.02.2024).
22. GradientBoostingRegressor / Scikit-Learn: site. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html> (дата обращения: 22.02.2024).

23. XGBRegressor / XGBoost: site. URL: [https://xgboost.readthedocs.io/en/release\\_3.2.0/python/python\\_api.html#xgboost.XGBRegressor](https://xgboost.readthedocs.io/en/release_3.2.0/python/python_api.html#xgboost.XGBRegressor) (дата обращения: 22.02.2024).
24. TimeSeriesSplit / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.TimeSeriesSplit.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html) (дата обращения: 19.02.2024).
25. GridSearchCV / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html) (дата обращения: 19.02.2024).
26. Dense Layer / Keras: site. URL: [https://keras.io/api/layers/core\\_layers/dense/](https://keras.io/api/layers/core_layers/dense/) (дата обращения: 06.03.2024).
27. Conv1D / TensorFlow: site. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/layers/Conv1D](https://www.tensorflow.org/api_docs/python/tf/keras/layers/Conv1D) (дата обращения: 09.03.2024).
28. SimpleRNN Layer / Keras: site. URL: [https://keras.io/api/layers/recurrent\\_layers/simple\\_rnn/](https://keras.io/api/layers/recurrent_layers/simple_rnn/) (дата обращения: 06.03.2024).
29. LSTM Layer / Keras: site. URL: [https://keras.io/api/layers/recurrent\\_layers/lstm/](https://keras.io/api/layers/recurrent_layers/lstm/) (дата обращения: 06.03.2024).
30. ForecastComb / Ceweiss: site. URL: <https://github.com/ceweiss/ForecastComb> (дата обращения: 21.03.2024).
31. Model Confidence Set Procedure / CRAN R Project: site. URL: <https://cran.r-project.org/web/packages/MCS/index.html> (дата обращения: 22.03.2024).
32. Shapley Additive Explanations / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/index.html> (дата обращения: 05.04.2024).
33. TreeExplainer / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/generated/shap.TreeExplainer.html> (дата обращения: 05.04.2024).
34. DeepExplainer / SHAP: site. URL: <https://shap.readthedocs.io/en/latest/generated/shap.DeepExplainer.html> (дата обращения: 06.04.2024).
35. Feature importance with a forest of trees / Scikit-Learn: site. URL: [https://scikit-learn.org/stable/auto\\_examples/ensemble/plot\\_forest\\_importances.html](https://scikit-learn.org/stable/auto_examples/ensemble/plot_forest_importances.html) (дата обращения: 10.04.2024).

**Литература на русском языке**

36. Абрамов В., Морозов А., Синяков А., Стерхова А. О роли глобальных факторов инфляции // Аналитическая записка Банка России. 2022.
37. Аверина Д., Горшкова Т., Синельникова-Мурылева Е. Построение кривой Филлипса на региональных данных // Экономический журнал ВШЭ. 2018. Т. 22. № 4. С. 609-630.
38. Акиндинова Н., Бессонов В., Пухов С., Сафонов И., Смирнов С. Инфляционные вызовы периоды пандемии и санкций // Вопросы экономики. 2018. № 5. С. 5-25.
39. Андреев А. Исследование асимметрии и нелинейности переноса динамики обменного курса в инфляцию // Серия докладов об экономических исследованиях Банка России. 2019. № 45.
40. Андреев А. Прогнозирование инфляции методом комбинирования прогнозов в Банке России // Серия докладов об экономических исследованиях Банка России. 2016. № 14.
41. Андреев М. Влияние бюджетного правила и модельных предпосылок на реакцию инфляции на шоки условий торговли // Серия докладов об экономических исследованиях Банка России. 2022. № 107.
42. Божечкова А., Джункеев У. CLARA и CARLSON: комбинации ансамблевых и нейросетевых методов машинного обучения для прогнозирования ВВП // Деньги и кредит. 2024. Т. 83. № 3. С. 45-69.
43. Божечкова А. В., Диденко Д. В., Джункеев У., Кончаков Р. Б. Человеческий капитал и экономическое развитие регионов России в контексте долгосрочной исторической динамики // Terra Economicus. 2024. Т. 22. № 2. С. 60-76.
44. Вереникин А. О. Денежная политика и экономический потенциал // Научные исследования экономического факультета. Электронный журнал. 2011. Т. 3. № 2.
45. Гафаров Б. Кривая Филлипса и становление рынка труда в России // Экономический журнал ВШЭ. 2011. Т. 15. № 2. С. 155-176.
46. Голощапова И., Андреев М. Оценка инфляционных ожиданий российского населения методами машинного обучения // Вопросы экономики. 2017. № 6. С. 71-93.

47. Дерюгина Е., Пономаренко А. Монетарный индикатор инфляционных рисков: модель переключения режимов // Вопросы экономики. 2013. № 9. С. 119-127.
48. Джункеев У. К. Моделирование влияния технологического развития и импорта на занятость в России // Вестник Московского университета. Серия 6. Экономика. 2023. Т. 58. № 6. С. 192-213.
49. Джункеев У. К. Моделирование влияния цифровых технологий на уровень безработицы в России // Вестник Московского университета. Серия 6. Экономика. 2021. № 6. С. 186-201.
50. Джункеев У. Прогнозирование безработицы в России с помощью методов машинного обучения // Деньги и кредит. 2022. Т. 81. № 1. С. 73-87.
51. Джункеев У. Прогнозирование инфляции в России на основе градиентного бустинга и нейронных сетей. 2024. Т. 83. № 1. С. 53-76.
52. Дробышевский С. М. Анализ рынка ГКО на основе изучения временной структуры процентных ставок // Институт экономики переходного периода. Научные труды. 1999. № 17Р.
53. Дробышевский С. М. Обзор современной теории временной структуры процентных ставок. Основные гипотезы и модели // Институт экономики переходного периода. Научные труды. 1999. № 14Р.
54. Зубарев А. Об оценке кривой Филлипса для российской экономики // Экономический журнал ВШЭ. 2018. Т. 22. № 1. С. 40-58.
55. Картаев Ф. С. Влияет ли выбор режима монетарной политики на инфляцию? // Вестник Московского университета. Серия 6. Экономика. 2016. № 5. С. 39-51.
56. Картаев Ф. С. Введение в эконометрику. М.: Экономический факультет МГУ имени М. В. Ломоносова. 2019. 472 с.
57. Картаев Ф. С., Беседовская М. Полезна ли кривая Филлипса для прогнозирования инфляции в России // Вестник Московского университета. Серия 6. Экономика. 2023. Т. 58. № 6. С. 24-43.
58. Картаев Ф. С., Черничин А. Финансовое развитие и успешность инфляционного таргетирования // Вестник Московского университета. Серия 6. Экономика. 2020. № 1. С. 41-61.
59. Картаев Ф. С., Леденева Е. Прозрачность монетарной политики и успешность инфляционного таргетирования // Экономическая политика. 2021. Т. 16. № 6. С. 8-33.

60. Картаев Ф. С., Медведев И. Денежно-кредитная политика и эффект переноса нефтяных цен в инфляцию // Вопросы экономики. 2020. № 8. С. 41-50.
61. Мухин Д. Краткосрочная кривая Филлипса и инфляционные процессы в России // Экономика и математические методы. 2010. Т. 46. № 2. С. 118-130.
62. Мясников А., Тарасов В., Аверьянова А., Ткаченко М. Оценка бюджетного импульса и его неоднородное влияние на инфляционные процессы в регионах России // Серия докладов об экономических исследованиях Банка России. 2023. № 118.
63. Орлов Д., Постников Е. Кривая Филлипса: инфляция и NAIRU в российских регионах // Серия докладов об экономических исследованиях Банка России. 2020.
64. Перевышин Ю. Н. Краткосрочное прогнозирование инфляции в российской экономике // Экономическая политика. 2022. Т. 17. № 5. С. 8-25.
65. Пестова А., Мамонов М. Оценка влияния различных шоков на динамику макроэкономических показателей в России и разработка условных прогнозов на основе BVAR-модели российской экономики // Экономическая политика. 2016. Т. 11. № 4. С. 56-92.
66. Петрова Д. Прогнозирование инфляции на основе интернет-запросов // Экономическое развитие России. 2019. Т. 26. № 11. С. 55-62.
67. Поршаков А., Пономаренко А. Проблемы идентификации и моделирования взаимосвязи монетарного фактора и инфляции в российской экономике // Вопросы экономики. 2008. № 7. С. 61-76.
68. Синяков А., Чернядьев Д., Сапова А. Оценка эффекта переноса валютного курса рубля в цены производителей конечной продукции на микроданных российских компаний // Журнал Новой экономической ассоциации. 2019. Т. 41. № 1. С. 128-157.
69. Соколова А. Инфляционные ожидания и кривая Филлипса: оценка на российских данных // Деньги и кредит. 2014. № 11. С. 61-67.
70. Третьяков Д., Фокин Н. Помогают ли высокочастотные данные в прогнозировании российской инфляции? // Вестник Санкт-Петербургского университета. Экономика. 2021. Т. 37. № 2. С. 318-343.
71. Трунин П., Пономарев Ю. Эффект переноса обменного курса в российской экономике // SSRN. 2014.
72. Хабибуллин Р. Какие показатели разрывов выпуска и реальной деловой активности позволяют прогнозировать инфляцию в России? // Серия докладов об экономических исследованиях Банка России. 2019. № 50.

### Литература на иностранных языках

73. Aanes B., Gullien M. Forecasting Norwegian Inflation with Deep Neural Networks. Bergen: Norwegian School of Economics.
74. Abel A., Bernanke B., Croushore D. Macroeconomics. Pearson. 8-th ed. 2014.
75. Ahmed N., Atiya N., El-Shishiny H. An Empirical Comparison of Machine Learning Methods for Time Series Forecasting // *Econometric Review*. 2010. Vol. 29. No. 5-6. P. 594-621.
76. Aiolfi M., Timmermann A. Persistence in forecasting performance and conditional combination strategies // *Journal of Econometrics*. 2006. Vol. 135. No. 1-2. P. 31-53.
77. Almosova A., Andersen N. Nonlinear inflation forecasting with recurrent neural networks // *Journal of Forecasting*. 2022. Vol. 22. No. 2. P. 1-20.
78. Ang A., Bekaert G., Wei M. Do macro variables, asset markets, or survey forecast inflation better? // *Journal of Econometrics*. 2007. Vol. 54. No. 4. P. 1163-1212.
79. Angelico C., Marcucci J., Miccoli M., Quarta F. Can we measure inflation expectations using Twitter? // *Journal of Econometrics*. 2022. Vol. 228. No. 2. P. 259-277.
80. Araujo G., Gaglianone W. Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models // *Latin America Journal of Central Banking*. 2023. Vol. 4. No. 2. P. 1-29.
81. Athey S., Imbens G. Machine Learning Methods That Economists Should Know About // *Annual Review of Economics*. 2019. Vol. 11. P. 685-725.
82. Atkenson A., Ohanian L. Are Phillips Curve Useful for Forecasting Inflation? // *Federal Reserve Bank of Minneapolis Quarterly Review*. 2001. Vol. 25. No. 1. P. 2-11.
83. Banbura M., Bobeica. Does the Phillips Curve help to forecast euro area inflation? // *International Journal of Forecasting*. 2023. Vol. 39. No. 1. P. 364-390.
84. Barkan O., Benchimol J., Caspi I., Cohen E., Hammer A., Koenigstein N. Forecasting CPI inflation components with Hierarchical Recurrent Neural Networks // *International Journal of Forecasting*. 2022. Vol. 39. No. 3. P. 1145-1162.
85. Bates J., Granger C. The Combination of Forecasts // *Operational Research*. 1969. Vol. 20. No. 4. P. 451-468.

86. Baybuza I. Inflation Forecasting Using Machine Learning Methods // Russian Journal of Money and Finance. 2018. Vol. 77. No. 4. P. 42-59.
87. Bernandi M., Catania L. The Model Confidence Set package for R // Journal of Computational Economics and Econometrics. 2018. Vol. 8. No. 2. P. 144-158.
88. Bjornland H., Jore A., Smith C., Thorsrud L. Improving and evaluating short term forecasts at the Norges Bank // Norges Bank Monetary Policy Staff Memo. 2008. No. 4.
89. Blanchard O. Macroeconomics. 2021. Pearson. 8-th ed.
90. Blanchard O. The Phillips Curve: Back to the '60s? // The American Economic Review. 2016. Vol. 106. No. 5. P. 31-34.
91. Blanchard O., Bernanke B. What caused the US pandemic-era inflation? // National Bureau of Economic Research Working Paper. 2023. No. 31417.
92. Brownlee J. Deep Learning for Time Series Forecasting. 2018. Machine Learning Mastery.
93. Bruneau C., Bandt O., Flageollet A., Michaux E. Forecasting Inflation Using Economic Indicators: The Case of France // Journal of Forecasting. 2007. Vol. 26. No. 1. P. 1-22.
94. Chakraborty C., Joseph A. Machine learning at central banks // Bank of England Staff Working Paper. 2017. No. 674.
95. Chan F., Pauwels L. Some theoretical results on forecast combinations // International Journal of Forecasting. 2018. Vol. 34. No. 1. P. 64-74.
96. Chen H., Covert I., Lundberg C., Lee S. Algorithms to estimate Shapley value feature attributions // Nature Machine Intelligence. 2023. Vol. 5. P. 590-601.
97. Cho K., van Merriënboer B., Bandanau D., Bengio Y. On the Properties of Neural Machine Translation: Encoder-Decoder Approaches // arXiv. 2014.
98. Chollet F. Deep Learning with Python. Manning Publications. 2014. 2-nd ed.
99. Chung J., Gulcehre C., Cho K., Bengion Y. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling // arXiv. 2014.
100. Claeskens G., Magnus J., Vasnev A., Wang W. The forecast combination puzzle: A simple theoretical explanation // International Journal of Forecasting. 2016. Vol. 32. No. 2. P. 754-762.
101. Cochrane J. Long-Term Debt and Optimal Policy in the Fiscal Theory of the Price Level // Econometrica. 2001. Vol. 69. No. 1. P. 69-116.
102. Cochrane J. The Fiscal Theory of the Price Level. New Jersey: The Princeton University Press. 2023.
103. Cogley T., Sargent T. The conquest of US inflation: Learning and robustness to model uncertainty // Review of Economic Dynamics. 2005. Vol. 8. No. 2. P. 528-563.

104. Coibion O., Gorodnichenko Y., Kamdar R. The Formation of Expectations, Inflation, and the Phillips Curve // *Journal of Economic Literature*. 2018. Vol. 56. No. 4. P. 1447-1491.
105. Croushore D., Stark T. A real-time data set for macroeconomists // *Journal of Econometrics*. 2001. Vol. 105. No. 1. P. 111-130.
106. Cybenko G. Approximation by Superpositions of a Sigmoidal Function // *Mathematics of Control, Signals, and Systems*. 1989. Vol. 2. P. 303-314.
107. Diebold F., Mariano R. Comparing Predictive Accuracy // *Journal of Business & Economic Statistics*. 1995. Vol. 13. No. 3. P. 134-144.
108. Ditzen J., Ravazzolo F. Dominant Drivers of National Inflation // *arXiv*. 2022.
109. Dorogush A., Ershov V., Gulin A. CatBoost: gradient boosting with categorical features support // *arXiv*. 2018.
110. Dougherty C. *Introductory Econometrics*. 2011. Oxford University Press. 4-th ed. 573 P.
111. Estrella A. Why Does the Yield Curve Predict Output and Inflation? // *The Economic Journal*. 2005. Vol. 115. No. 505. P. 722-744.
112. Fan J., Ma C., Zhong Y. A Selective Overview of Deep Learning // *Statistical Science*. 2021. Vol. 36. No. 2. P. 264-290.
113. Faust J., Wright J. Forecasting Inflation // *Handbook of Economic Forecasting*. 2013. Vol. 2. Ch. 1. P. 2-56.
114. Fisher I. A Statistical Relation between Unemployment and Price Changes // *International Labour Review*. 1926. Vol. 13. No. 6. P. 785-792.
115. Fisher I. I Discovered the Phillips Curve: A Statistical Relationship between Unemployment and Price Changes // *Journal of Political Economy*. 1973. Vol. 81. No. 2. P. 496-502.
116. Forni M., Hallin M., Reichlin L. Do financial variables help forecasting inflation and real activity in the euro area? // *The Journal of Monetary Economics*. 2003. Vol. 50. No. 6. P. 1243-1255.
117. Freund Y., Schapire R. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting // *Journal of Computer and System Sciences*. 1997. Vol. 55. No. 1. P. 119-139.
118. Friedman M. Nobel Lecture: Inflation and Unemployment // *Journal of Political Economy*. 1977. Vol. 85. No. 3. P. 451-472.
119. Friedman M. The Role of Monetary Policy // *The American Economic Review*. 1968. Vol. LVIII. No. 1. P. 1-17.

120. Fulton C., Hubrich K. Forecasting US Inflation in Real Time // *Econometrics*. 2021. Vol. 9. No. 36. P. 1-20.
121. Gali J., Gertler M. Inflation dynamics: A structural econometric analysis // *Journal of Monetary Economics*. 1999. Vol. 44. No. 2. P. 195-222.
122. Garcia M., Medeiros M., Vasconcelos G. Real-time inflation forecasting with high-dimensional models: The case of Brazil // *International Journal of Forecasting*. 2017. Vol. 33. P. 679-693.
123. Geerolf F. The Phillips Curve: A Relation between Real Exchange Rate Growth and Unemployment. 2020.
124. Giannone D., Lenza M., Momferatou D., Onorante L. Short-term inflation projections: A Bayesian vector autoregressive approach // *International Journal of Forecasting*. 2014. Vol. 30. P. 635-644.
125. Giannone D., Lenza M., Primiceri G. Prior Selection for Vector Autoregression // *The Review of Economics and Statistics*. 2015. Vol. 97. No. 2. P. 436-451.
126. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. The MIT Press. 2016. 1-st ed.
127. Gornostaev D., Ponomarenko A., Seleznev S., Sterkhova A. Historical Database of Macroeconomic Indicators for Russia // *Russian Journal of Money and Finance*. 2022. Vol. 81. No. 1. P. 88-103.
128. Goryunov E., Drobyshevsky S., Kudrin A., Trunin P. Factors of global inflation in 2021-2022 // *Russian Journal of Economics*. 2023. No. 9. P. 219-244.
129. Hansen P., Lunde A., Nason J. The Model Confidence Set // *Econometrica*. 2011. Vol. 79. No. 2. P. 453-497.
130. Harding M., Linde J., Trabandt M. Resolving the missing deflation puzzle // *Journal of Monetary Economics*. 2022. Vol. 126. P. 15-34.
131. Harding M., Linde J., Trabandt M. Understanding Post-COVID inflation Dynamics // *Journal of Monetary Economics*. 2023. Vol. 140. P. S101-S118.
132. Harvey D., Leybourne S., Newbold P. Testing the equality of predictive mean squared errors // *International Journal of Forecasting*. 1997. Vol. 13. No. 2. P. 281-291.
133. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning. Data Mining, Inference, and Prediction*. New York: Springer. 2009.
134. Hauzenberger N., Huber F., Klieber K., Marcellino M. Enhanced Bayesian Neural Networks for Macroeconomics and Finance // *arXiv*. 2022.

135. Hauzenberger N., Huber F., Klieber K. Real-time inflation forecasting using non-linear dimension reduction techniques // *International Journal of Forecasting*. 2023. Vol. 39. P. 901-921.
136. Hazell J., Harreno J., Nakamura E., Steinsson J. The Slope of the Phillips Curve: Evidence from U.S. States // *The Quarterly Journal of Economics*. 2022. Vol. 137. No. 3. P. 1299-1344.
137. Hinton G., Vinyals O., Dean J. Distilling the Knowledge in a Neural Network // *arXiv*. 2015.
138. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9. No. 8. P. 1735-1780.
139. Hubrich K., Skudelny F. Forecast Combination for Euro Area Inflation: A Cure in Times of Crisis? // *Journal of Forecasting*. 2017. Vol. 36. P. 515-540.
140. Inoue A., Kilian L. How Useful Is Bagging in Forecasting Economic Time Series? A Case Study of U.S. Consumer Price Inflation // *Journal of the American Statistical Association*. 2008. Vol. 103. No. 482. P. 511-522.
141. Inoue A., Kilian L. On the selection of forecasting models // *Journal of Econometrics*. 2006. Vol. 130. No. 2. P. 273-306.
142. Jacobson T., Karlsson S. Finding Good Predictors for Inflation: A Bayesian Model Averaging Approach // *Journal of Forecasting*. 2004. Vol. 23. P. 479-496.
143. Joseph A., Potjagailo G., Kalamara E., Chakraborty C., Kapetanios G. Forecasting UK inflation bottom up // *The Bank of England Staff Working Paper*. 2022. No. 915.
144. Kapetanios G., Labhard V., Price S. Forecasting Using Bayesian and Information-Theoretic Model Averaging: An Application to U.K. Inflation // *Journal of Business & Economic Statistics*. 2008. Vol. 26. No. 1. P. 33-41.
145. Karpathy A., Johnson J., Fei-Fei L. Visualizing and Understanding Recurrent Neural Networks // *arXiv*. 2015.
146. Kartaev P., Luneva I. Shaken, not Stirred: Comparing the Effectiveness of Pure and Hybrid Inflation Targeting // *Russian Journal of Money and Finance*. Vol. 77. No. 3. P. 65-75.
147. Kascha C., Ravazzolo F. Combining Inflation Density Forecasts // *Journal of Forecasting*. 2010. Vol. 29. P. 231-250.
148. Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q., Liu T. LightGBM: A Highly Efficient Gradient Boosting Decision Tree // *Proceedings of the 31<sup>st</sup> International Conference on Neural Information Processing Systems*. 2017. P. 3149-3157.

149. Kingma D., Ba J. Adam: A Method for Stochastic Optimization // arXiv. 2017
150. Kinlaw W., Kritzman M., Metcalfe M., Turkington D. The Determinants of Inflation // MIT Sloan Research Paper. 2022. No. 6730.
151. Kiranyaz S., Avcı O., Abdeljaber O., Ince T., Gabbouj M. Inman D. 1D convolutional neural networks and applications: A survey // Mechanical Systems and Signal Processing. 2021. Vol. 151. P. 1-21.
152. Kiselev A., Zhivaykina A. The role of global relative price changes in international comovement of inflation // The journal of Economic Asymmetries. 2020. Vol. 22. No. e00175.
153. Kohlscheen E. What does machine learning say about the drivers of inflation // Bank of International Settlements Working Paper. 2022. No. 980.
154. Koop G., Korobilis D. Forecasting Inflation Using Dynamic Model Averaging // International Economic Review. 2012. Vol. 53. No. 3. P. 867-886.
155. Koop G., Potter S. Forecasting in dynamic factor model using Bayesian model averaging // Econometrics Journal. 2004. Vol. 7. No. 2. P. 550-565.
156. LeCun Y., Bengio Y., Hinton G. Deep Learning // Nature. 2015. Vol. 521. P. 436-444.
157. Longo L., Soltaneih-H M. SHAPoly: A novel Shapley-polynomial framework for estimating nonlinear dynamics in macroeconomic data using deep neural networks // SSRN. 2023.
158. Lucas R. Econometric policy evaluation: A critique // Carnegie-Rochester Conference Series on Public Policy. 1976. Vol. 1. P. 19-46.
159. Lucas R. Nobel Lecture : Monetary Neutrality // Journal of Political Economy. 1996. Vol. 104. No. 4. P. 661-682.
160. Lundberg S., Lee S. A Unified Approach to Interpreting Model Predictions // Proceedings of the 31<sup>st</sup> International Conference on Neural Information Processing Systems. 2017. P. 4768-4777.
161. Lundberg S., Erion G., Chen H., DeGrave A., Prutkin J., Nair B., Katz R., Himmerfarb J., Bansal N., Lee S. From local explanations to global understanding with explainable AI for trees // Nature Machine Intelligence. 2020. No. 5. P. 56-67.
162. Mamedli M., Shubitov D. Forecasting Russian CPI with Data Vintages and Machine Learning Techniques // The Bank of Russia Working Paper. 2021. No. 70.
163. Mankiw G. Macroeconomics. New York: Worth Publishers. 2010. 7-th ed.

164. Mavroedis S., Plagborg-Moller M., Stock J. Empirical Evidence on Inflation Expectations in the New Keynesian Phillips Curve // *Journal of Economic Literature*. 2014. Vol. 52 No. 1. P. 124-188.
165. Medeiros M., Schutte E., Soussi T. Global Inflation : Implications for forecasting and monetary policy // SSRN. 2023.
166. Medeiros M., Vasconcelos G., Veiga A., Zilberman E. Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods // *Journal of Business & Economic Statistics*. 2019. Vol. 39. No. 1. P. 98-119.
167. Miranda-Agrippino S., Rey H. U.S. Monetary Policy and the Global Financial Cycle // *Review of Economic Studies*. 2020. Vol. 87. P. 2754-2776.
168. Moshiri S., Cameron N. Neural Network Versus Econometric Models in Forecasting Inflation // *Journal of Forecasting*. 2000. Vol. 19. No. 3. P. 201-217.
169. Mundell R. A Reconsideration of the Twentieth Century // *The American Economic Review*. 2000. Vol. 90. No. 3. P.327-340.
170. Murphy K. Probabilistic Machine Learning. 2022. Cambridge: The MIT Press.
171. Nagy E., Tengey V. External and Domestic Drivers of Inflation: The Case Study of Hungary // *Russian Journal of Money and Finance*. 2018. Vol. 77. No. 3. P. 49-64.
172. Nakamura E. Inflation forecasting using a neural network // *Economics Letters*. 2005. Vol. 86. No. 3. P. 373-378.
173. Ogunc F., Akdogan K., Baser S., Chadwick M., Ertug D., Hulagu T., Kosem S., Ozmen M., Tekatli N. Short-term inflation forecasting model for Turkey and a forecast combination analysis // *Economic Modeling*. 2013. Vol. 33. P. 312-325.
174. Paranhos S. Predicting Inflation with Neural Networks // arXiv. 2021.
175. Pavlov E. Forecasting Inflation in Russia Using Neural Networks // *Russian Journal of Money and Finance*. 2020. Vol. 79. No. 1. P. 57-73.
176. Perevyshin Y. Analysts' Inflation Expectations vs Univariate Models of Inflation Forecasting in the Russian Economy // *Russian Journal of Money and Finance*. 2024. Vol. 83. No. 2. P. 57-76.
177. Phelps E. Money-Wage Dynamics and Labor-Market Equilibrium // *Journal of Political Economy*. 1968. Vol. 76. No. 4. P. 678-711.
178. Phillips A. The Relation between Unemployment and the Rate of Change of Money Rates in the United Kingdom // *Economica*. 1958. Vol. 25. No. 100. P. 283-299.

179. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A., Gulin A. CatBoost: unbiased boosting with categorical features // Proceedings of the 32<sup>nd</sup> International Conference on Neural Information Processing Systems. 2018. P. 6639-6649.
180. Samuelson P., Solow R. Analytical Aspects of Anti-Inflation Policy // The American Economic Review. 1960. Vol. 50. No. 2. P. 177-194.
181. Sargent T., Williams H., Zha T. Shocks and Government Beliefs: The Rise and Fall of American Inflation // The American Economic Review. 2006. Vol. 96. No. 4. P. 1193-1224.
182. Sargent T., Wallace N. Some Unpleasant Monetarist Arithmetic // Federal Reserve Bank of Minneapolis Quarterly Review. 1981. Vol. 5. No. 3. P. 1-17.
183. Saul S. Do global output gaps help forecast inflation in Russia? // The Bank of Russia Working Paper. 2021. No. 85.
184. Semiturkin O., Shevelev A. Correct Comparison of Predictive Features of Machine Learning Methods: The Case of Forecasting Inflation Rates in Siberia // Russian Journal of Money and Finance. 2023. Vol. 82. No. 1. P. 87-103.
185. Shulyak E. Macroeconomic Forecasting Using Data from Social Media // Russian Journal of Money and Finance. 2022. Vol. 81. No. 4. P. 86-112.
186. Sims C. Statistical Modeling of Monetary Policy and Its Effects // The American Economic Review. 2012. Vol. 102. No. 4. P. 1187-1205.
187. Sims C. Stepping on a rake: The role of fiscal policy in the inflation of the 1970s // European Economic Review. 2012. Vol. 55. No. 1. P. 48-56.
188. Sims C., Zha T. Bayesian methods for dynamic multivariate models // International Economic Review. 1998. Vol. 39. No. 4. P. 949-968.
189. Smith J., Wallis K. A Simple Explanation of the Forecast Combination Puzzle // Oxford Bulletin of Economics and Statistics. 2009. Vol. 71. No. 3. P. 331-355.
190. Stark T., Croushore D. Forecasting with a real-time data set for macroeconomists // Journal of Macroeconomics. 2002. Vol. 24. No. 4. P. 507-531.
191. Steel M. Model Averaging and Its Use in Economics // Journal of Economic Literature. 2020. Vol. 58. No. 3. P. 644-719.
192. Stella A., Stock J. A State-Dependent Model for Inflation Forecasting // Board of Governors of the Federal Reserve System International Finance Discussion Paper. 2013. No. 1062.
193. Stock J., Watson M. Forecasting Inflation // Journal of Monetary Economics. 1999. Vol. 44. No. 2. P. 293-335.

194. Stock J., Watson M. Forecasting Output and Inflation: The Role of Asset Prices // *Journal of Economic Literature*. 2003. Vol. 41. No. 3. P. 788-829.
195. Stock J., Watson M. Why Has U. S. Inflation Become Harder to Forecast? // *Journal of Money, Credit and Banking*. 2007. Vol. 39. No. 1. P. 3-33.
196. Stock J., Watson M. Phillips Curve Inflation Forecasts // *NBER Working Paper*. 2008. No. 14322.
197. Stock J., Watson M. *Introduction to Econometrics* // Pearson. 2020. 4-th ed. 796 P.
198. Styrin K. Forecasting Inflation in Russia by Dynamic Model Averaging // *Russian Journal of Money and Finance*. 2019. Vol. 78. No. 1. P. 3-18.
199. Styrin K., Zamulin O. A Real Exchange Rate Based Phillips Curve // *Centre for Economic and Financial Research at New Economic School Working Paper*. 2012. No. 179.
200. Szafranek K. Bagged neural networks for forecasting Polish (low) inflation // *International Journal of Forecasting*. 2019. Vol. 35. No. 3. P. 1042-1059.
201. Timmermann A. Forecast Combinations // *Handbook of Economic Modelling*. 2006. P. 135-196.
202. Tobin J. Inflation and Unemployment // *The American Economic Review*. 1972. Vol. 62. No. 1/2. P. 1-18.
203. Verbeek M. *A Guide to Modern Econometrics* // Wiley. 2017. 5-th ed. 508 P.
204. Wang Z., Hyndman R., Li F., Kang Y. Forecast combinations: an over 50-year review // *International Journal of Forecasting*. 2023. Vol. 39. No. 4. P. 1518-1547.
205. Wiess C., Raviv E., Roetzer G. Forecast Combinations in R using the ForecastComb Package // *The R Journal*. 2018. Vol. 10. No. 2. P. 262-281.
206. Woolridge J. *Introductory Econometrics: A Modern Approach*. 2018. Cengage. 7-th ed.
207. Wright J. Forecasting US Inflation by Bayesian Model Averaging // *Journal of Forecasting*. 2009. Vol. 28. No. 2. P. 131-144.
208. Zeng J. Forecasting Aggregates with Disaggregate Variables: Does Boosting Help to Select the Most Relevant Predictors? // *Journal of Forecasting*. 2017. Vol. 36. No. 1. P. 74-90.

## Приложения

### Приложение А




Рисунок А1 – Прогноз темпов роста индекса потребительских цен (ИПЦ) по нейронным сетям на 1 месяц вперед. Период: январь 2014 г. – январь 2019 г. Источник: составлено автором




Рисунок А2 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 3 месяца вперед. Период: март 2014 г. – март 2019 г. Источник: составлено автором




Рисунок А3 – Прогноз инфляции по нейронным сетям на 3 месяца вперед. Период: март 2014 г. – март 2019 г. Источник: составлено автором




Рисунок А4 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 6 вперед. Период: июнь 2014 г. – июнь 2019 г. Источник: составлено автором

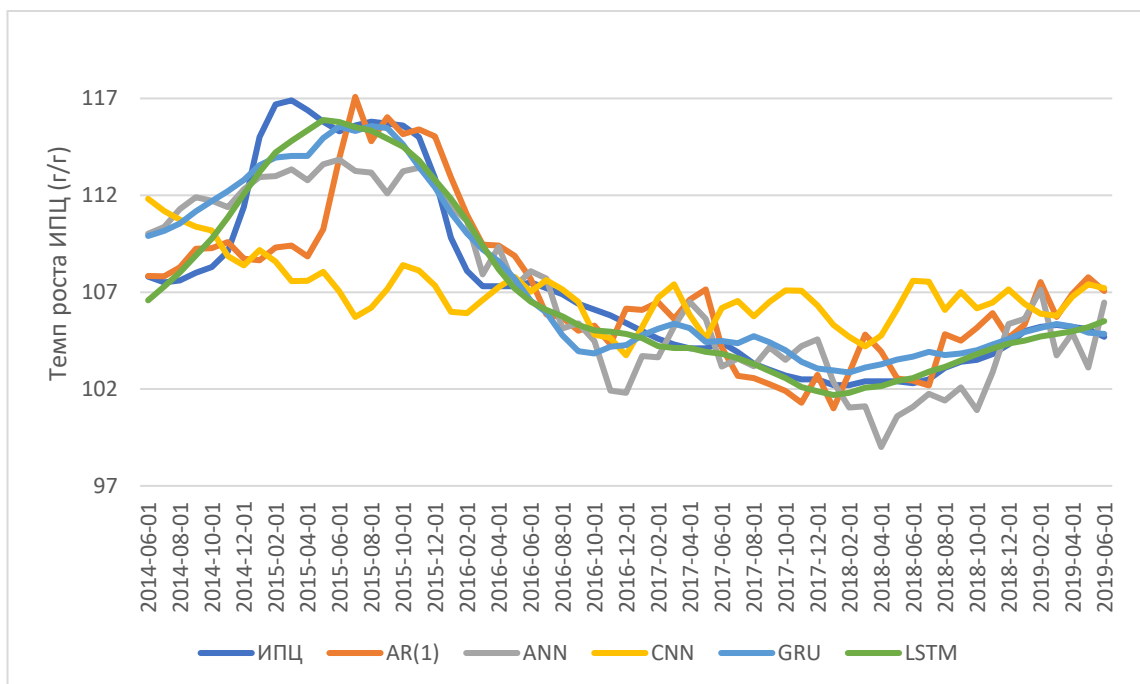


Рисунок А5 – Прогноз инфляции по нейронным сетям на 6 месяцев вперед. Период: июнь 2014 г. – июнь 2019 г. Источник: составлено автором




Рисунок А6 – Прогноз инфляции по моделям градиентного бустинга, нейронных сетей на 9 месяцев вперед. Период: сентябрь 2014 г. – сентябрь 2019 г. Источник: составлено автором




Рисунок А7 – Прогноз инфляции по нейронным сетям на 9 месяцев вперед. Период: сентябрь 2014 г. – сентябрь 2019 г. Источник: составлено автором




Рисунок А8 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 12 месяцев вперед. Период: декабрь 2014 г. – декабрь 2019 г. Источник: составлено автором




Рисунок А9 – Прогноз инфляции по нейронным сетям на 12 месяцев вперед. Период: декабрь 2014 г. – декабрь 2019 г. Источник: составлено автором




Рисунок А10 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 1 месяц вперед. Период: февраль 2019 г. – май 2022 г. Источник: составлено автором




Рисунок А11 – Прогноз инфляции по нейронным сетям на 1 месяц вперед. Период: февраль 2019 г. – май 2022 г. Источник: составлено автором




Рисунок А12 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 3 месяца вперед. Период: апрель 2019 г. – июль 2022 г. Источник: составлено автором




Рисунок А13 – Прогноз инфляции по нейронным сетям на 3 месяца вперед. Период: апрель 2019 г. – июль 2022 г. Источник: составлено автором




Рисунок А14 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 6 месяцев вперед. Период: июль 2019 г. – октябрь 2022 г. Источник: составлено автором




Рисунок А15 – Прогноз инфляции по нейронным сетям на 6 месяцев вперед. Период: июль 2019 г. – октябрь 2022 г. Источник: составлено автором




Рисунок А16 – Прогноз инфляции по моделям градиентного бустинга, нейронных сетей на 9 месяцев вперед. Период: октябрь 2019 г. – январь 2023 г. Источник: составлено автором




Рисунок А17 – Прогноз инфляции по нейронным сетям на 9 месяцев вперед. Период: октябрь 2019 г. – октябрь 2023 г. Источник: составлено автором

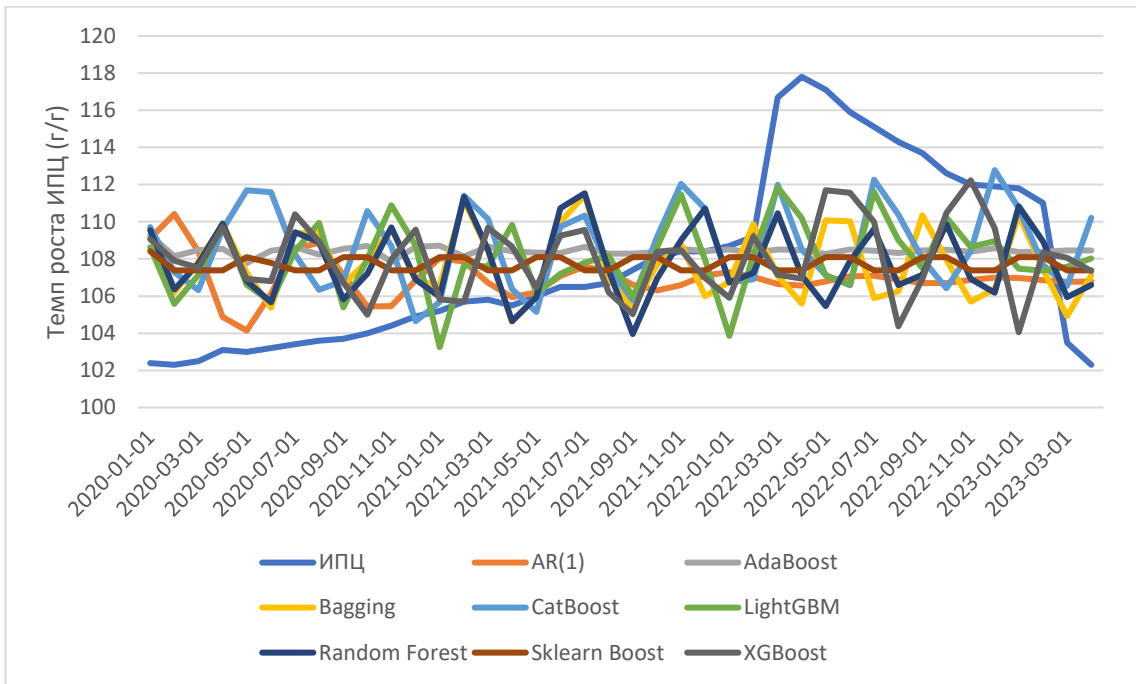


Рисунок А18 – Прогноз инфляции по моделям градиентного бустинга, случайного леса на 12 месяцев вперед. Период: январь 2020 г. – апрель 2023 г. Источник: составлено автором




Рисунок А19 – Прогноз инфляции по нейронным сетям на 12 месяцев вперед. Период: январь 2020 г. – апрель 2023 г. Источник: составлено автором