

УДК 336.6

DOI: <https://doi.org/10.17323/ej.2026.33568>

Наукастинг агрегированных финансовых индикаторов российских предприятий¹

Чудаева А.Б.

Исследование посвящено разработке модельного аппарата для наукастинга (оценки текущего состояния) показателей финансового состояния российских организаций, официальная статистика по которым становится доступна с задержкой. Рассматривается 16 целевых переменных, в число которых входят прибыль предприятий, оборотные и внеоборотные активы, выручка, расходы различных категорий, показатели общей и просроченной задолженности, в рамках различных секторов: сельское хозяйство, добыча полезных ископаемых, обрабатывающие производства, строительство, торговля и экономика в целом. В качестве предикторов берутся оперативно публикуемые экономические и финансовые индикаторы российской экономики, в том числе учитывающие отраслевую специфику. Внимание фокусируется на построении интервальных (вероятностных) наукастов, которые отражают более полную картину динамики переменных и позволяют оценивать риски. Несмотря на обилие отечественных исследований по наукастингу макроэкономических показателей, в том числе с использованием методов вероятностного прогнозирования, проблема оперативной оценки агрегированных финансовых индикаторов ранее не затрагивалась. В работе используются такие инструменты, как линейная регрессия, квантильная регрессия и квантильная нейронная сеть. Предикторы подбираются с помощью линейной и квантильной LASSO-регрессий. Качество моделей сравнивается с авторегрессией первого порядка и динамической факторной моделью. После тестирования на исторических данных для каждой целевой переменной выбирается оптимальная модель. Согласно полученным результатам, для построения наукастов выбранных индикаторов следует использовать разные инструменты. Тем не менее нейронная сеть, обладающая преимуществом

¹ Статья подготовлена по результатам исследований, выполненных за счет средств Научного фонда Финансового университета.

Чудаева Александра Борисовна – стажер-исследователь Института исследований социально-экономических трансформаций и финансовой политики Финансового университета при Правительстве Российской Федерации. E-mail: sasha.chudaeva@yandex.ru

Статья поступила: 22.10.2025/Статья принята: 19.02.2026.

моделирования сложных нелинейных зависимостей, оказывается лучшим подходом к интервальному и точечному наукастингу для наибольшего числа целевых показателей. Построенные модели могут использоваться управляющими органами для получения оперативных данных по финансовым индикаторам и разработки своевременных мер по поддержке российских предприятий, а также в рамках таких задач, как оценка долговой нагрузки и финансовой устойчивости бизнеса, планирование бюджетных поступлений, планирование налоговой политики.

Ключевые слова: наукастинг; финансовые показатели; российские предприятия; отрасли; сектора; интервальные наукасты; квантильная регрессия; нейронная сеть; LASSO-регрессия.

Для цитирования: Чудаева А.Б. Наукастинг агрегированных финансовых индикаторов российских предприятий. *Экономический журнал ВШЭ*. 2026; 30(1): 9–48.

For citation: Chudaeva A.B. Nowcasting Aggregate Financial Indicators of Russian Enterprises. *HSE Economic Journal*. 2026; 30(1): 9–48. (In Russ.)

1. Введение

Статистические данные являются основой для мониторинга и контроля экономических процессов. Поскольку сбор и обработка информации требует временных затрат, официальная статистика нередко становится доступна гораздо позже отчетного периода, что затрудняет принятие оперативных и своевременных решений в области экономической политики. В этих условиях становится актуальным применение подхода наукастинга (nowcasting). В рамках задачи наукастинга, как разновидности прогнозирования, на основе доступных данных производится оценка текущего состояния системы.

Одними из индикаторов, публикуемых с задержкой, являются совокупные финансовые показатели российских предприятий, такие как прибыль, доходы, расходы, активы и долговые обязательства. При этом оперативные данные по агрегированным показателям корпоративной отчетности способны дать общую картину текущего положения бизнеса и могут быть полезны управляющим органам для реализации разноплановых задач: от оценки финансовой устойчивости и платежеспособности компаний до планирования налоговой политики и разработки поддерживающих мер.

Так, настоящая работа ставит своей целью построение и оценку прогнозных свойств моделей для наукастинга индикаторов финансового состояния российских организаций на уровне всей экономики и в отраслевом разрезе. Отметим, что в современных условиях внешней и внутренней экономической нестабильности ключевую роль играет проблема управления рисками. В связи с этим особенностью исследования выступает фокус не только на точечных, но и на интервальных (вероятностных) прогнозах с использованием квантильной регрессии и квантильной нейронной сети. Данные инструменты позволяют корректно оценивать и анализировать как центральные тенденции, так и неопределенность в траектории развития переменных.

В отечественной литературе существует немало работ на тему наукастинга российских макроэкономических переменных, официальная статистика по которым выходит с большой задержкой. Внимание авторов в основном сосредоточено на ВВП и его компонентах по использованию: конечному потреблению, валовому накоплению капитала, экспорту и импорту [Зубарев, Рыбак, 2021; Рыбак, 2023; Гареев, Полбин, 2022; Фокин, 2023; Зубарев и др., 2022]. Наукастину составляющих ВВП также посвящена серия исследований [Макеева, Станкевич, 2022; Станкевич, 2023; Макеева и др., 2024; Макеева, 2025]. В отдельных работах разрабатываются инструменты для построения наукастов ВДС отраслей российской промышленности [Крыжановский и др., 2025], разрыва выпуска [Ляхнова, Коленко, 2024], товарных категорий экспорта и импорта [Майорова, Фокин, 2021]. Отметим, что проблема оценки текущих значений агрегированных показателей финансового состояния организаций не рассматривалась в существующих научных публикациях.

Тем не менее стоит подчеркнуть, что в контексте российских исследований наработан достаточно богатый опыт в плане применения различных подходов к наукастину. Для получения оперативных оценок макропоказателей используются как эконометрические методы, среди которых динамическая факторная модель (DFM) [Зубарев, Рыбак, 2021; Рыбак, 2023; Макеева и др., 2024; Макеева, 2025], байесовская векторная авторегрессия (BVAR) [Зубарев и др., 2022], модель со смешанными данными (MIDAS) [Макеева, Станкевич, 2022; Станкевич, 2023; Макеева и др., 2024; Макеева, 2025], модель MIDAS с марковским переключением [Станкевич, 2023], байесовская векторная авторегрессия с данными смешанной частотности (MFBVAR) [Макеева, Станкевич, 2022; Фокин, 2023; Станкевич, 2023; Макеева и др., 2024; Макеева, 2025], так и инструменты машинного обучения: модели с регуляризацией типов L1 и L2, случайный лес, градиентный бустинг [Майорова, Фокин, 2021; Гареев, Полбин, 2022; Макеева, Станкевич, 2022; Станкевич, 2023; Макеева, 2025], которые актуальны при работе с большими объемами данных. В исследовании [Крыжановский и др., 2025] для получения оперативных данных применяется нейронная сеть долгой краткосрочной памяти.

Макеева [Макеева, 2025] поднимает достаточно интересный вопрос влияния последовательного уточнения наблюдений (ревизии), которое проводится статистическими службами, на точность наукастов. Разные версии временных рядов используются как для обучения моделей, так и в качестве фактических значений целевых переменных на тестовом периоде. Некоторые работы посвящены анализу релевантности специфических предикторов в рамках задачи наукастинга: в работах [Рыбак, 2023; Зубарев и др., 2022] тестируются модели с включением дополнительных глобальных факторов, в [Макеева и др., 2024] строится собственный индикатор эмоциональной окраски новостного фона на основе данных Telegram-каналов, которые обрабатываются с помощью нейронной сети BERT.

Несмотря на разнообразие подходов к моделированию и множество предложений по совершенствованию методологии наукастинга, упомянутые работы фокусируются на построении точечных прогнозов показателей. В то же время в мировой литературе крайне популярным направлением является построение интервальных (вероятностных) наукастов на основе квантильных эконометрических моделей, в частности квантильной регрессии [Carriero et al., 2020; Mitchell et al., 2022]. Преимущество подобного рода инструментов заключается в более корректном моделировании функции распределения целевой переменной и, соответственно, возможности оценивать риски ее экстремального роста и снижения в условиях неопределенности. Базовой работой по анализу хвостовых

рисков выступает статья [Adrian et al., 2019]. Стоит заметить, что на данный момент применение квантильных моделей к задачам наукастинга и краткосрочного прогнозирования российских показателей реализовано в крайне малом количестве работ. В недавнем исследовании [Полбин, Шумилов, 2025] квантильная регрессия и ее модификации используются для оценки текущих и будущих значений элементов ВВП. Авторы отмечают высокое качество прогнозов, полученных на основе многофакторных квантильных моделей в рамках задачи наукастинга потребления домохозяйств и инвестиций. В работе [Казакова, Фокин, 2024] строятся интервальные прогнозы инфляции с помощью обычной и сглаженной квантильных регрессий и также демонстрируется преимущество рассмотренных моделей над их линейными аналогами.

Таким образом, настоящая работа посвящена разработке моделей для оперативной оценки совокупных финансовых индикаторов российских предприятий ввиду поздней публикации официальных данных и отсутствия отечественных исследований по данной теме. Решается задача построения как точечных, так и интервальных наукастов, которые позволяют судить о неопределенности в динамике переменных. В работе используются квантильная регрессия [Koenker, 2005], в рамках которой оценивается отдельное уравнение для каждого квантиля распределения целевого показателя, многофакторные линейные регрессии (в том числе DFM) и авторегрессия. Также апробируется продвинутый подход квантильной нейронной сети, которая способна оперировать сложными нелинейными зависимостями между квантилями целевой переменной и предикторами [Taylor, 2000; Cannon, 2011]. Модель в основном нашла применение в литературе по прогнозированию погодных условий и различных показателей в сфере энергетики, показав довольно успешные результаты [Cannon, 2011; He et al., 2016; He, Li, 2018]. Для выбора предикторов применяются инструменты машинного обучения, а именно линейная и квантильная LASSO-регрессии (least absolute shrinkage and selection operator). Последняя позволяет выделить релевантные предикторы индивидуально для каждого квантиля целевой переменной и обеспечивает более качественную подстройку под данные в рамках квантильных моделей. Согласно выводам текущего исследования, квантильная нейронная сеть является перспективным инструментом наукастинга экономических переменных, поскольку производит наиболее точные оценки большинства целевых показателей на тестовом периоде для различных секторов экономики. Предложенный модельный аппарат позволяет строить достаточно качественные вероятностные и точечные наукасты для многих индикаторов финансового состояния организаций. Оперативные оценки могут быть получены в течение месяца после окончания отчетного периода, в то время как официальная статистика становится доступна с задержкой около двух месяцев.

Статья организована следующим образом. В разделе 2 приводится подробная характеристика целевых переменных и предикторов. В разделе 3 представлены спецификации конкурирующих моделей и формулы для расчета критериев качества наукастов. Раздел 4 посвящен обсуждению результатов тестирования прогнозных свойств моделей на исторических данных: приводятся значения метрик и графики наукастов, выбирается лучшая модель для каждой целевой переменной. Раздел 5 завершает проведенный анализ: формулируются итоги исследования и его практическая ценность, предлагаются направления для дальнейшей работы.

2. Описание данных и выбор предикторов

Целевыми переменными выступают агрегированные показатели российских предприятий, которые публикуются на сайте Единой межведомственной информационной службы в разделе «1.32.6 Финансовое состояние организаций»². Для исследования были отобраны наиболее общие индикаторы по группам «Активы организаций», «Доходы и расходы», «Показатели финансового состояния и расчетов»³. В дополнение рассматривается часть кредиторской задолженности – совокупная задолженность по платежам в Федеральный бюджет и бюджеты субъектов РФ. В контексте долговых показателей представлена как общая сумма, так и просроченная составляющая.

Для более углубленного анализа берутся финансовые индикаторы предприятий из следующих отраслей экономики: «Сельское, лесное хозяйство, охота, рыболовство и рыбоводство» (SH), «Добыча полезных ископаемых» (DPI), «Обрабатывающие производства» (OP), «Строительство» (STR), «Торговля оптовая и розничная, ремонт автотранспортных средств и мотоциклов» (TR), «Экономика в целом» (ALL). Итого в рамках шести секторов рассматривается по 16 целевых показателей.

В табл. 1 приводится полный перечень объясняемых переменных с указанием на их условное обозначение, периодичность и формат обработки данных. Показатели имеют квартальную или месячную частоту. Отметим, что официальная статистика по выбранным индикаторам становится доступна с задержкой в 2 месяца после окончания отчетного периода (19–23-й рабочий день после месяца, следующего за отчетным). Графики обработанных значений целевых переменных для категории «Экономика в целом» представлены на рис. П1 в Приложении.

Исходные наблюдения по показателям выручки (SALE), себестоимости продукции (COST), коммерческих расходов (CME), процентных платежей (LP) и прибыли (EBT) переводятся из формата «значение за период с начала года по рассматриваемый квартал (месяц)» в «значение за рассматриваемый квартал (месяц)». Далее временные ряды приводятся к стационарному виду путем взятия первой разности логарифма и домножения на 100%, что дает процентный прирост показателя к предыдущему периоду. Стоит отметить, что переменная прибыли (EBT) содержит отрицательные значения, а значит, к ней неприменима процедура логарифмирования. В данном случае для устранения стохастического тренда используется нормирование: рассчитывается процентное отношение текущего значения прибыли (EBT) к выручке (SALE) прошлого периода. Поскольку исходный ряд EBT имеет месячную частоту, а SALE – квартальную, предварительно вычисляется суммарное по месяцам значение EBT в рамках каждого квартала. Расширенный тест Дики – Фуллера спецификации с константой и глубиной лага, подобранной по критерию Шварца, отвергает нулевую гипотезу о наличии единичного корня для всех обработанных рядов на уровне значимости 10%.

² См.: <https://www.fedstat.ru/organizations/> (дата обращения 20 декабря 2025).

³ См.: <https://www.fedstat.ru/form/10183> (дата обращения 20 декабря 2025).

Таблица 1.

Целевые переменные

Группа	Имя	Пояснение	Формат	Частота
Активы	NCA	Внеоборотные активы	Прирост, %	Квартал
	CA	Стоимость оборотных активов крупных и средних организаций	Прирост, %	Квартал
Доходы и расходы	SALE	Выручка (нетто) от продажи товаров, продукции, работ, услуг за минусом НДС, акцизов и иных аналогичных обязательных платежей	Прирост, %	Квартал
	COST	Себестоимость проданных товаров, продукции, работ, услуг	Прирост, %	Квартал
	CME	Коммерческие и управленческие расходы	Прирост, %	Квартал
	FA	Выручка от продажи основных средств	Прирост, %	Квартал
	LP	Расходы на проценты по кредитам	Прирост, %	Квартал
	Финансовое состояние и расчеты	EBT	Прибыль до налогообложения	Рост относительно прошлого SALE, %
AR		Дебиторская задолженность организаций	Прирост, %	Месяц
AP		Кредиторская задолженность организаций	Прирост, %	Месяц
BD		Задолженность по платежам в бюджет	Прирост, %	Месяц
LD		Задолженность по полученным кредитам и займам крупных и средних предприятий и организаций	Прирост, %	Месяц
OAR		Просроченная дебиторская задолженность организаций	Прирост, %	Месяц
OAP		Просроченная кредиторская задолженность организаций	Прирост, %	Месяц
OBD		Просроченная задолженность по платежам в бюджет	Прирост, %	Месяц
OLD		Просроченная задолженность по полученным кредитам и займам крупных и средних предприятий и организаций	Прирост, %	Месяц

В качестве объясняющих переменных были взяты макроэкономические и финансовые индикаторы, сведения о которых приведены в табл. 2. Согласно методологии отечественных работ по наукастингу, например, [Макеева, Станкевич, 2022; Фокин, 2023], в число предикторов входят основные показатели экономики, которые характеризуют об-

ший уровень экономической активности (индекс производства, оборот торговли и уровень безработицы), внутренние цены и условия внешней торговли (индекс потребительских цен, индекс цен производителей, валютный курс, мировые цены на нефть, газ и пшеницу), а также ряд финансовых индикаторов: фондовый индекс, денежный агрегат, объем кредитования, ставка MIACR. Помимо этого рассматриваются опросные опережающие индикаторы⁴: индекс предпринимательской уверенности, динамика выпуска и динамика прибыли.

При наличии данных в набор предикторов включались показатели не только по экономике в целом, но и на уровне интересующих отраслей. Отметим, что критериями подбора объясняющих переменных выступали оперативность их публикации в соответствующих источниках (не более месяца после окончания отчетного периода) и наличие длинного ряда исторических значений.

Все ряды предикторов, за исключением индикаторов динамики прибыли и физического объема работ, а также индексов уверенности в строительстве и торговле⁵, имеют ежемесячную частоту и переводятся в квартальный формат для использования в моделях с квартальными объясняемыми переменными. При конвертации рассчитывается арифметическое среднее значение показателя по месяцам в рамках каждого квартала. Далее с целью приведения переменных к стационарному виду вычисляется первая разность логарифма (процентный прирост к предыдущему периоду). В случае уровня безработицы, процентной ставки, индексов уверенности и опросных оценок рассматривается абсолютное изменение показателя. Согласно результатам теста Дики – Фуллера обработанные временные ряды не содержат единичного корня на уровне значимости 10%.

Подавляющее большинство предикторов, как и целевых переменных, определено на интервале с января 2005 г. (I квартала 2005 г.) по май 2025 г. (II квартал 2025 г.).

Таблица 2.

Объясняющие переменные

Имя	Пояснение	Сектора	Формат	Источник	Публикация
IP	Индекс производства	ALL, SH, DPI, OP, STR	Прирост, %	Росстат	Конец месяца, следующего за отчетным
ORT	Оборот розничной торговли	–	Прирост, %	Росстат	Конец месяца, следующего за отчетным
U	Уровень безработицы в возрасте 15–72 лет	–	Разность, п.п.	Росстат	Конец месяца, следующего за отчетным
CPI	Индекс потребительских цен	–	Прирост, %	Росстат	6–10-й рабочий день после отчетного периода

⁴ См.: https://rosstat.gov.ru/leading_indicators (дата обращения 20 декабря 2025).

⁵ Имеют квартальную частоту и не используются в моделях для месячных целевых переменных.

Окончание табл. 2.

Имя	Пояснение	Сектора	Формат	Источник	Публикация
PPI	Индекс цен производителей	ALL, SH, DPI, OP, STR	Прирост, %	Росстат	Конец месяца, следующего за отчетным
ER	Номинальный эффективный валютный курс (количество валюты за 1 рубль)	–	Прирост, %	Банк международных расчетов	Вторая половина месяца, следующего за отчетным
OIL	Мировые цены на сырую нефть марки Brent	–	Прирост, %	Международный валютный фонд	Вторая половина месяца, следующего за отчетным
GAS	Мировые цены на природный газ	–	Прирост, %	Международный валютный фонд	Вторая половина месяца, следующего за отчетным
WHT	Мировые цены на пшеницу	–	Прирост, %	Международный валютный фонд	Вторая половина месяца, следующего за отчетным
CNF	Индекс предпринимательской уверенности	DPI, OP, STR, TR	Разность, п.п.	Росстат	Без задержки
OUT	Опросная оценка динамики выпуска основного вида продукции	DPI, OP	Разность, п.п.	Росстат	Без задержки
FO	Опросная оценка динамики физического объема работ	STR	Разность, п.п.	Росстат	Без задержки
PRF	Опросная оценка динамики прибыли	TR	Разность, п.п.	Росстат	Без задержки
IMX	Индекс МосБиржи	–	Прирост, %	Московская Биржа	Без задержки
M	Денежный агрегат M2	–	Прирост, %	Банк России	Конец месяца, следующего за отчетным
CRT	Объем кредитов, депозитов и прочих средств, предоставленных предприятиям	–	Прирост, %	Банк России	Конец второго месяца, следующего за отчетным ⁶
R	Средняя фактическая ставка по однодневным кредитам, предоставленным московскими банками	–	Разность, п.п.	Банк России	До 15 числа после отчетного периода

⁶ Показатель используется в моделях с лагом в 1 месяц.

В дальнейшем анализе в целях снижения риска переобучения моделей и решения проблемы коррелированности регрессоров отдельно для каждой целевой переменной по каждому сектору экономики производится подбор предикторов посредством алгоритма LASSO-регрессии (см. раздел 3). При отборе рассматривается весь набор показателей (29 предикторов для квартальных данных, 25 для месячных данных), а также лаги целевых переменных и сезонные фиктивные переменные⁷. Отметим, что по итогам отбора каждый индикатор из табл. 2 вошел хотя бы в одно уравнение среди всех целевых переменных для 6 секторов в различные моменты построения наукастов, т.е. все временные ряды предикторов в той или иной степени полезны.

В табл. П1 в Приложении представлены списки объясняющих переменных из табл. 2, которые выбираются чаще остальных в рамках регрессий для условного среднего (линейных LASSO-регрессий) и регрессий для условных квантилей с вероятностью 20%, 50%, 80% (квантильных LASSO-регрессий) при рассмотрении финансовых показателей по экономике в целом. Наборы предикторов для различных целевых переменных достаточно разнообразны, однако в большинстве случаев в списке присутствует хотя бы один индикатор из категорий: уровень экономической активности, внутренние цены, мировые цены на сырьевые товары и валютный курс, показатели финансового рынка. Подчеркнем, что важную роль играют опросные опережающие индикаторы. Помимо этого, даже на агрегированном уровне оказывается важна отраслевая специфика – крайне часто в уравнения для переменных по экономике в целом входят показатели отдельных секторов. При рассмотрении целевых показателей на дезагрегированном уровне наблюдается похожая ситуация, однако чаще можно увидеть именно те индикаторы, которые соответствуют отрасли (индексы производства, цены производителей, опросные оценки).

Также можно заметить, что релевантные предикторы для медианного квантиля, как правило, имеют некоторые пересечения с предикторами для условного среднего, но все же отличаются, что демонстрирует разницу в подходах квантильной и линейной регрессий. Кроме того, наборы показателей для нижнего, среднего и верхнего квантилей преимущественно разные. Следовательно, в рамках квантильных моделей имеет место неоднородность влияния объясняющих переменных на центральную часть, левый и правый хвост прогнозных функций распределения.

3. Описание моделей и метрик качества

3.1. Модели для наукастинга

В качестве инструментов для построения интервальных и точечных наукастов финансовых показателей рассматриваются 5 конкурирующих моделей временных рядов. Среди них: однофакторная и многофакторная линейные регрессии (в том числе динамическая факторная модель), а также нелинейные модели – квантильная регрессия и квантильная нейронная сеть. При отборе предикторов применяется алгоритм LASSO.

Моделируются квантили целевых переменных с вероятностью τ от 0,1 до 0,9 с шагом 0,1. Интервальные наукасты линейных моделей рассчитываются на основе нормаль-

⁷ Необходимы, так как временные ряды некоторых предикторов и целевых переменных характеризуются сезонными колебаниями.

ного распределения с математическим ожиданием, равным прогнозу среднего значения, и стандартным отклонением, которое соответствует стандартной ошибке прогноза. Наукасты, построенные с использованием квантильных моделей, обрабатываются при помощи ядерной оценки плотности с гауссовым ядром – алгоритма, который позволяет интерполировать и сглаживать прогнозные оценки функции распределения.

Целевыми переменными являются показатели финансового состояния организаций из табл. 1 для различных секторов экономики: сельское хозяйство и рыболовство, добыча полезных ископаемых, обрабатывающая промышленность, строительство, торговля и экономика в целом.

3.1.1. Авторегрессионная модель AR(1)

Базовой моделью (бенчмарком) выступает линейная авторегрессия порядка 1. Оцененное уравнение имеет вид (1).

$$(1) \quad \hat{y}_t = \hat{\alpha} + \hat{\beta}y_{t-1},$$

где y_t – целевая переменная в момент t ; $\hat{\alpha}$ – константа; $\hat{\beta}$ – коэффициент.

3.1.2. Динамическая факторная модель DFM

В качестве второго бенчмарка была выбрана динамическая факторная модель, популярный в отечественной и зарубежной литературе инструмент для наукастинга ВВП (см., например: [Зубарев, Рыбак, 2021]). Для получения рядов ненаблюдаемых факторов применяются функции из библиотеки statsmodels для программной среды Python. Выделяется 3 ненаблюдаемых фактора. В рамках процедуры используются наблюдаемые показатели российской экономики из табл. 2. Данные предварительно стандартизируются и при необходимости очищаются от сезонности с помощью регрессии на сезонные фиктивные переменные. Предполагается, что ненаблюдаемые факторы подчиняются процессу авторегрессии порядка 1. Общая постановка модели имеет вид (2–3).

Далее текущие и лаговые значения полученных факторов, а также собственный лаг целевой переменной и сезонные дамми включаются в линейную регрессию (4). Отметим, что динамическая факторная модель обучается на выборке, оканчивающейся периодом, на который строится наукаст. Затем уравнение (4) оценивается на данных до момента наукаста.

$$(2) \quad X_t = \Lambda F_t + \varepsilon_t,$$

$$(3) \quad F_t = \Omega F_{t-1} + \upsilon_t,$$

$$(4) \quad \hat{y}_t = \hat{\alpha} + \hat{\beta}y_{t-1} + \sum_{i=1}^3 \hat{\theta}_i^0 f_{i,t} + \sum_{i=1}^3 \hat{\theta}_i^1 f_{i,t-1} + \sum_{i=1}^{P_y} \hat{d}_i s_{i,t},$$

где X_t – вектор наблюдаемых переменных в момент t ; F_t – вектор ненаблюдаемых факторов в момент t ; Λ , Ω – матрицы коэффициентов; ε_t , υ_t – векторы случайных оши-

бок; $\hat{\theta}_i^0, \hat{\theta}_i^1, \hat{d}_i$ – коэффициенты; $f_{i,t}$ – i -ый ненаблюдаемый фактор в момент t ; p_y – количество сезонных дамми-переменных, зависящее от частотности целевого показателя (3 в случае квартальных данных, 11 в случае месячных данных); $s_{i,t}$ – i -ая сезонная дамми-переменная в момент t (первая дамми-переменная указывает на первый период в рамках года в соответствии с частотностью целевого показателя, вторая – на второй и т.д.).

3.1.3. Линейная регрессия LR

Линейная регрессия с выбранными объясняющими переменными. Отбор предикторов производится на каждой обучающей выборке с помощью линейной LASSO-регрессии, затем переменные с ненулевыми коэффициентами включаются в итоговое уравнение (5). Алгоритм реализован в библиотеке scikit-learn на языке Python. В процессе отбора участвуют все показатели из табл. 2, а также сезонные дамми-переменные (3 для квартальных данных, 11 для месячных данных) и запаздывающие значения всех целевых переменных, имеющих ту же частотность, в рамках рассматриваемой отрасли (лаг глубины 1 для квартальных данных, 2 для месячных данных). Данные предварительно стандартизируются. Константа входит в уравнение в обязательном порядке. Гиперпараметр силы регуляризации подбирается при помощи кросс-валидации на основе первой тренировочной выборки (по декабрь 2022 г.) с целевой метрикой continuous ranked probability score (CRPS) [Carriero et al., 2022], которая оценивает качество прогноза всей функции распределения целевой переменной.

$$(5) \quad \hat{y}_t = \hat{\alpha} + \sum_{i=1}^n \hat{\beta}_i x_{i,t},$$

где n – количество предикторов, выбранных для рассматриваемой целевой переменной; $\hat{\beta}_i$ – коэффициент при i -ом предикторе; $x_{i,t}$ – значение i -го предиктора в момент t .

3.1.4. Квантильная регрессия QR

Квантильная регрессия, предложенная в работе [Koenker, 2005], с выбранными объясняющими переменными. Модель предполагает построение отдельного уравнения для каждого из квантилей целевой переменной и таким образом позволяет воспроизводить функции распределения произвольной формы. При оценке минимизируется асимметрично-взвешенная сумма модулей ошибок прогноза (6). На случаи, когда фактическое значение переменной превышает смоделированный «высокий» квантиль (с вероятностью более 0,5), и наоборот, когда фактическое значение меньше предсказанного «низкого» квантиля (с вероятностью менее 0,5), накладывается более сильный штраф.

$$(6) \quad \sum_t \omega_t(\tau) |y_t - Q_{y_t}(\tau|x)|, \quad \omega_t(\tau) = I_{(y_t \geq Q_{y_t}(\tau|x))} \tau + I_{(y_t < Q_{y_t}(\tau|x))} (1 - \tau),$$

где τ – вероятность квантиля; $I_{(*)}$ – индикаторная функция.

Выбор объясняющих переменных реализуется с помощью квантильной LASSO-регрессии из библиотеки scikit-learn для языка Python. В отличие от линейной версии предикторы отбираются для каждого квантиля индивидуально, что обеспечивает более тонкую подстройку под данные. Для упрощения гиперпараметр силы регуляризации предполагается одинаковым для всех квантильных уравнений в рамках одной целевой переменной. В остальном процесс отбора схож с процедурой, описанной в пункте 3.1.3.

Итоговое уравнение для условного квантиля, которому соответствует вероятность τ , представлено выражением (7).

$$(7) \quad \hat{Q}_{y_i}(\tau | x) = \hat{\alpha}^\tau + \sum_{i=1}^{n_\tau} \hat{\beta}_i^\tau x_{i,t},$$

где n_τ – количество предикторов, выбранных для квантиля τ рассматриваемой целевой переменной; $\hat{\alpha}^\tau$ – константа в уравнении для квантиля τ ; $\hat{\beta}_i^\tau$ – коэффициент при i -ом предикторе в уравнении для квантиля τ .

3.1.5. Квантильная нейронная сеть QRNN

Квантильная нейронная сеть (*quantile regression neural network, QRNN*) на базе многослойного перцептрона с выбранными объясняющими переменными. Необходимые инструменты доступны в библиотеке qrnn в программной среде R [Cannon, 2011]. В рамках данной модели, как и в случае квантильной регрессии, для каждого квантиля целевого показателя строится и оценивается индивидуальное уравнение. Преимуществом подхода выступает учет возможной нелинейной связи между предикторами и квантилем объясняемой переменной. При обучении нейронной сети минимизируется сглаженная аппроксимация функции (6). Для корректности результатов к временным рядам объясняемых и объясняющих переменных предварительно применяется процедура стандартизации.

В соответствии с методологией [He et al., 2019], входные переменные квантильной нейронной сети предварительно отбираются с помощью алгоритма LASSO. В данном случае предикторы идентичны объясняющим переменным из модели QR.

Уравнение для условного квантиля с вероятностью τ имеет вид (8). Рассматриваемая модель содержит один скрытый слой⁸ с K нейронами. Внутри скрытого слоя производится нелинейное преобразование линейной комбинации предикторов, в свою очередь выходной слой обрабатывает сигналы скрытого слоя и дает итоговое значение целевого показателя.

$$(8) \quad \hat{Q}_{y_i}(\tau | x) = \hat{\alpha}^\tau + \sum_{k=1}^K \hat{\phi}_k^\tau \gamma_{k,t}(*), \quad \gamma_{k,t}(*) = \phi \left(\tilde{\alpha}_k^\tau + \sum_{i=1}^{n_\tau} \hat{\beta}_{k,i}^\tau x_{i,t} \right),$$

где $\hat{\alpha}^\tau$ – константа выходного слоя в уравнении для квантиля τ ; K – количество скрытых нейронов; $\hat{\phi}_k^\tau$ – коэффициент при выходном значении k -го нейрона в уравнении для

⁸ Эксперименты по использованию квантильной нейронной сети с двумя скрытыми слоями не привели к положительному результату.

квантиля τ ; $\gamma_{k,t}(\ast)$ – выходное значение k -го нейрона для момента t ; $\phi(\ast)$ – функция активации нейрона; $\tilde{\alpha}_k^\tau$ – константа k -го нейрона в уравнении для квантиля τ ; $\hat{\beta}_{k,i}^\tau$ – коэффициент при i -ом предикторе в k -ом нейроне в уравнении для квантиля τ .

Гиперпараметры нейросетевой модели подбираются с помощью кросс-валидации на основе данных первой обучающей выборки. Как и ранее, минимизируется метрика CRPS. Рассматриваются два варианта функции активации $\phi(\ast)$ – гиперболический тангенс (T), и Rectified Linear Unit (R), также перебирается количество скрытых нейронов K от 1 до 7. Оптимальные значения гиперпараметров для каждой из целевых переменных представлены в табл. П2 и П3 в Приложении.

3.2. Критерии качества прогнозов

Для сравнения качества точечных наукастов среднего используется традиционная метрика RMSE (root mean squared error), которая рассчитывается по формуле (9). При рассмотрении квантильных моделей предварительно вычисляется среднее значение прогнозного распределения. Помимо этого, для проверки статистической значимости различий между ошибками прогнозов моделей по критерию RMSE проводится тест Диболда – Мариано с квадратичной функцией потерь. Стоит отметить, что данный тест, к сожалению, не позволяет сопоставлять качество интервальных наукастов.

$$(9) \quad \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2},$$

где T – объем тестовой подвыборки; y_t – наблюдение целевой переменной в момент t ; \hat{y}_t – предсказанное значение целевой переменной для момента t .

Качество медианных наукастов оценивается с помощью метрики MAE (mean absolute error) (10). Отметим, что в случае линейных регрессий прогноз медианы совпадает со средним значением распределения.

$$(10) \quad \frac{1}{T} \sum_{t=1}^T |y_t - \hat{Q}_{y_t}(0,5|x)|,$$

где $\hat{Q}_{y_t}(0,5|x)$ – предсказанное значение медианы целевой переменной для момента t .

При сопоставлении интервальных наукастов или же прогнозных функций распределения рассматривается критерий CRPS (continuous ranked probability score) [Carriero et al., 2022], вычисляемый по формуле (11). Метрика представляет собой усредненное по всем спрогнозированным квантилям значение асимметрично-взвешенной функции потерь (6), которая минимизируется при обучении квантильной регрессии и квантильной нейронной сети. Выбранная функция весов $\rho(\tau)$ является наиболее универсальной в контексте рассматриваемых целевых показателей: больший вес присваивается квантилям из центральной части распределения.

$$(11) \quad \frac{2}{q} \sum_{\tau} \rho(\tau) \left(\frac{1}{T} \sum_{t=1}^T \omega_t(\tau) |y_t - \hat{Q}_{y_t}(\tau|x)| \right),$$

$$\tau = 0, 1, 0, 2, \dots, 0, 9,$$

$$\rho(\tau) = \tau(1 - \tau),$$

$$\omega_t(\tau) = I_{(y_t \geq \hat{Q}_{y_t}(\tau|x))} \tau + I_{(y_t < \hat{Q}_{y_t}(\tau|x))} (1 - \tau),$$

где q – количество оцененных квантилей; τ – вероятность квантиля; $\hat{Q}_{y_t}(\tau|x)$ – предсказанное значение квантиля τ целевой переменной для момента t ; $I_{(*)}$ – индикаторная функция.

4. Результаты апробации моделей

4.1. Оценка качества наукастов

Наукасты строятся по схеме расширяющегося окна ввиду относительно небольшого числа наблюдений. В соответствии с календарем выхода официальной статистики по объясняющим переменным данные эксперименты предполагают, что наукасты целевых показателей для конкретного периода строятся в конце месяца, следующего за этим периодом. В свою очередь, фактические наблюдения по целевым переменным становятся доступны в конце второго месяца после этого периода. Первая тренировочная (обучающая) выборка ограничивается справа декабрем или IV кварталом 2022 г. в зависимости от периодичности целевого показателя. На ее основе строятся наукасты на январь или I квартал 2023 г. Далее тренировочный период сдвигается вперед на одно наблюдение до тех пор, пока не достигнет апреля 2025 г. или IV квартала 2024 г. Последнее тестируемое наблюдение – май или I квартал 2025 г. Ввиду того, что не все временные ряды предикторов доступны с 2005 г., объемы обучающих выборок для различных целевых переменных могут не совпадать. Объем тестовой выборки в случае месячных данных – 29 месяцев⁹, для квартальных – 9 кварталов.

Результаты расчета критериев RMSE и CRPS для различных моделей и объясняемых переменных на уровне всей экономики приводятся в табл. 3 и 4. Сравнение моделей по метрике MAE представлено в табл. П4 в Приложении. Более низкое значение метрик соответствует более высокому качеству модели. Кроме того, в табл. П5 в Приложении отражены результаты теста Диболда – Мариано на сравнение RMSE моделей относительно бенчмарка AR(1) с двусторонней альтернативной гипотезой.

Таблицы П6–П8 в Приложении содержат сведения о том, какая из моделей оказалась оптимальной для каждой целевой переменной в рамках различных отраслей экономики по метрикам RMSE, CRPS и MAE соответственно. Результаты могут использоваться при наукастинге финансовых показателей российских предприятий как в целом по экономике, так и на отраслевом уровне. В табл. 5 представлена сводная информация о количе-

⁹ OAR по экономике в целом и OAR для всех секторов имеют два пропущенных значения.

стве целевых показателей, для которых та или иная модель оказалась наилучшей, суммарно и в разрезе отдельных секторов. Приведены расчеты для различных критериев качества.

Таблица 3.

**Сравнение качества моделей по метрике RMSE
для экономики в целом**

Модель	AR(1)	DFM	LR	QR	QRNN
NCA	1,76	2,65	1,65*	1,12***	1,19**
CA	2,96	2,53*	2,70	2,09**	1,77***
SALE	11,16	2,73*	4,60	2,40**	1,69***
COST	11,15	3,22*	4,99	2,38***	2,56**
CME	6,23	2,01***	2,12**	3,12	3,08*
FA	77,90	41,00	36,90***	39,37*	38,71**
LP	24,43**	57,85	83,49	30,51*	19,27***
EBT	3,40*	2,77***	3,65	3,84	3,24**
AR	1,86*	2,06	1,79***	1,90	1,80**
AP	1,99**	2,80	1,99**	2,07	1,93***
BD	12,26	12,32	9,54**	9,62*	9,25***
LD	1,85	1,76	1,66*	1,46***	1,55**
OAR	4,22	3,63*	3,54***	3,60**	3,69
OAP	2,60***	3,48	3,70	3,17*	3,06**
OBD	9,12	7,32**	7,63	7,53*	6,78***
OLD	9,97	7,60*	8,21	7,54***	7,58**

Примечание: метрика RMSE рассчитывается на основе точечных наукастов, в рамках квантильных моделей рассматривается прогноз среднего значения; тремя астерисками отмечен наилучший результат, двумя и одним астериском – результат второго и третьего ранга соответственно.

Таблица 4.

**Сравнение качества моделей по метрике CRPS
для экономики в целом**

Модель	AR(1)	DFM	LR	QR	QRNN
NCA	0,315	0,333	0,180*	0,136***	0,140**
CA	0,341	0,316*	0,348	0,273**	0,232***
SALE	1,374	0,327**	0,550	0,328*	0,272***
COST	1,375	0,386*	0,615	0,294***	0,334**

Окончание табл. 4.

Модель	AR(1)	DFM	LR	QR	QRNN
CME	0,769	0,227***	0,388*	0,380**	0,405
FA	9,318	5,240	4,512*	3,964**	3,821***
LP	6,127*	6,820	10,018	3,284**	2,735***
EBT	0,397*	0,354***	0,436	0,468	0,384**
AR	0,217*	0,275	0,215**	0,226	0,207***
AP	0,231**	0,354	0,235*	0,242	0,224***
BD	1,437	1,413	0,928**	0,943*	0,879***
LD	0,225	0,194	0,177*	0,156**	0,155***
OAR	0,520	0,505	0,421***	0,441*	0,439**
OAP	0,317***	0,429	0,444	0,384*	0,368**
OBD	1,050	0,940	0,917*	0,915**	0,846***
OLD	0,883	0,784*	0,863	0,719**	0,702***

Примечание: метрика CRPS оценивает качество интервальных наукастов (наукастов всей функции распределения); тремя астерисками отмечен наилучший результат, двумя и одним астериском – результат второго и третьего ранга соответственно.

Как видно из табл. 3–4 и табл. П4 в Приложении, наукасты, построенные по квантильной нейронной сети (QRNN) с предикторами, отобранными с помощью алгоритма квантильной LASSO-регрессии, являются самыми точными для наибольшего числа целевых переменных на уровне всей экономики. Особенно успешный результат наблюдается в рамках наукастов всей функции распределения и медианного значения: нейросетевая модель лидирует у 10 из 16 и 11 из 16 показателей соответственно. Отметим, что квантильная нейронная сеть, как правило, оказывается не самым худшим вариантом, т.е. прогнозные свойства модели достаточно стабильны.

Квантильная регрессия (QR) с теми же предикторами также дает довольно качественный результат и оказывается на втором или третьем месте для большого числа общероссийских целевых показателей по различным критериям. Так, можно заключить, что учет неоднородности влияния предикторов на квантили целевой переменной, реализуемый при построении индивидуальных квантильных уравнений в рамках квантильной регрессии, а также моделирование более сложных нелинейных форм зависимости посредством квантильной нейронной сети зачастую положительно сказываются на точности интервальных и точечных наукастов.

В свою очередь, многофакторные линейные регрессии, динамическая факторная модель (DFM) и модель с предикторами, подобранными на основе линейной LASSO-регрессии, (LR), в основном выигрывают у авторегрессионной модели AR(1). И, как видно из табл. П5 в Приложении, различия по критерию RMSE зачастую статистически значимы. Из этого следует, что используемые объясняющие переменные достаточно информативны и способствуют улучшению прогнозных свойств моделей.

Таблица 5.

**Количество целевых переменных,
для которых модель выбрана лучшей**

Метрика	Модель	Сектор						Всего
		SH	DPI	OP	STR	TR	ALL	
RMSE	AR(1)	3**	1	2	3*	8***	1	18**
	DFM	2	2*	2	4**	3**	2	15*
	LR	2	1	2	1	1	3*	10
	QR	0	5**	2	0	1	4**	12
	QRNN	9***	7***	8***	8***	3**	6***	41***
CRPS	AR(1)	1	0	1	1	6***	1	10*
	DFM	1	1*	1	2**	4**	2**	11**
	QR	1	2**	2**	0	2	2**	9
	QRNN	10***	13***	12***	12***	4**	10***	61***
MAE	AR(1)	1	0	1	4**	9***	2**	17**
	DFM	1	4**	1	1*	3**	2**	12*
	LR	3**	2	2*	0	1	1	9
	QR	1	2	3**	0	0	0	6
	QRNN	10***	8***	9***	11***	3**	11***	52***

Примечание: тремя астерисками отмечен наилучший результат среди моделей в рамках рассматриваемого сектора и критерия качества, двумя и одним астериском – результат второго и третьего ранга соответственно.

При тестировании моделей в отраслевом разрезе были получены схожие выводы. Согласно табл. 5, по метрикам RMSE, CRPS и MAE квантильная нейронная сеть (QRNN) оказывается оптимальной моделью наиболее часто и, как правило, с большим отрывом. Это касается всех отраслей, кроме торговли. Сектор «Торговля оптовая и розничная, ремонт автотранспортных средств и мотоциклов» в целом относительно плохо поддается прогнозированию – в случае приростов оборотных активов (CA), прибыли (EBT), дебиторской задолженности (AR), общей и просроченной кредиторской задолженности (AP, OAP) лучшей моделью для построения наукастов выступает AR(1), прогнозы которой маловариативны (см. табл. П6–П8 в Приложении и рис. П6 в Приложении), реже лидерами оказываются динамическая факторная модель (DFM) и квантильная нейронная сеть (QRNN). Вероятной причиной является многогранность торговой деятельности вкупе с недостаточной информативностью выбранных для нее предикторов. В дальнейшем следовало бы добавить в число объясняющих переменных более специфичные показатели, а именно: оборот оптовой торговли, оборот организаций оптовой и розничной торговли, а также опережаю-

щие опросные индикаторы для сектора розничной торговли – складские запасы, цены реализации, обеспеченность собственными финансовыми ресурсами, экономическая ситуация, недостаточный платежеспособный спрос, недостаток финансовых средств. Кроме того, важной переменной может выступать состояние конкурентной среды.

Отметим, что для экономики в целом показатель прироста просроченной кредиторской задолженности (ОАР) можно охарактеризовать как труднопрогнозируемый: оптимальной моделью для точечного и вероятностного наукастинга оказывается авторегрессия порядка 1, которая дает довольно тривиальные предсказания, близкие к константе (см. график ОАР на рис. 2). Также в некоторых секторах, помимо торговли, возникают трудности с наукастингом приростов общей и просроченной кредиторской задолженности (АР, ОАР), общей задолженности по кредитам (LD) и внеоборотных активов (NCA) (см. табл. П6–П8 в Приложении и рис. П2–П5 в Приложении). Учитывая, что общая и просроченная задолженности по платежам в бюджет (BD, OBD), которые являются частью общей и просроченной кредиторской задолженности (АР, ОАР), прогнозируются достаточно хорошо, можно предположить, что затруднения связаны именно с долгами по расчетам с поставщиками и страховым взносам. Для улучшения качества наукастов, в том числе по долговым показателям, в число предикторов можно включить опросные оценки недостатка финансовых средств, недостатка оборудования, высокого процента коммерческого кредита (для секторов добыча полезных ископаемых, обрабатывающие производства), динамики экономической ситуации (для секторов строительство, добыча полезных ископаемых, обрабатывающие производства), а также оборот организаций всего и по видам экономической деятельности. Кроме того, в проведенных экспериментах лаги квартальных целевых показателей не задействуются при наукастинге месячных целевых показателей и наоборот. Смешение частотности могло бы улучшить прогнозные свойства моделей.

Подчеркнем, что выделить модели второго и третьего ранга по количеству случаев «оптимальности» довольно трудно. Линейная (LR) и квантильная (QR) регрессии являются лучшими относительно редко, но все же остаются важны для отдельных целевых переменных. Таким образом, весь модельный аппарат, используемый в текущем исследовании, может быть полезен в рамках задачи наукастинга финансовых индикаторов российских предприятий. Отметим также, что для многих показателей в плане точечного и интервального наукастинга лидирует одна и та же модель. Так, можно выделить единую стратегию по построению наукастов как всей функции распределения в целом, так и центральной тенденции в частности.

На рис. 1–2 представлены наукасты целевых переменных для экономики в целом и их фактические наблюдения. Отображены интервальные и точечные (средние) значения по наилучшим моделям, которые были выбраны согласно критериям качества из табл. 3–4. На рис. П2–П6 в Приложении приводятся графики для отраслевых показателей.

Исходя из рис. 1–2, можно отметить, что предложенная в настоящей работе процедура для наукастинга дает качественные интервальные и точечные предсказания общероссийских приростов выручки от реализации продукции (SALE), себестоимости продукции (COST), коммерческих и управленческих расходов (CME), задолженности по бюджетным платежам (BD), задолженности по кредитам и займам (LD) – фактические наблюдения переменных крайне близки к спрогнозированной траектории. Также имеет место хороший результат для приростов следующих показателей: внеоборотные (NCA) и оборотные (CA) активы организаций, выручка от продажи основных средств (FA) и просроченная задол-

женность по кредитам и займам (OLD). На отраслевом уровне (см. рис. П2–П6 в Приложении) прослеживаются похожие тенденции.

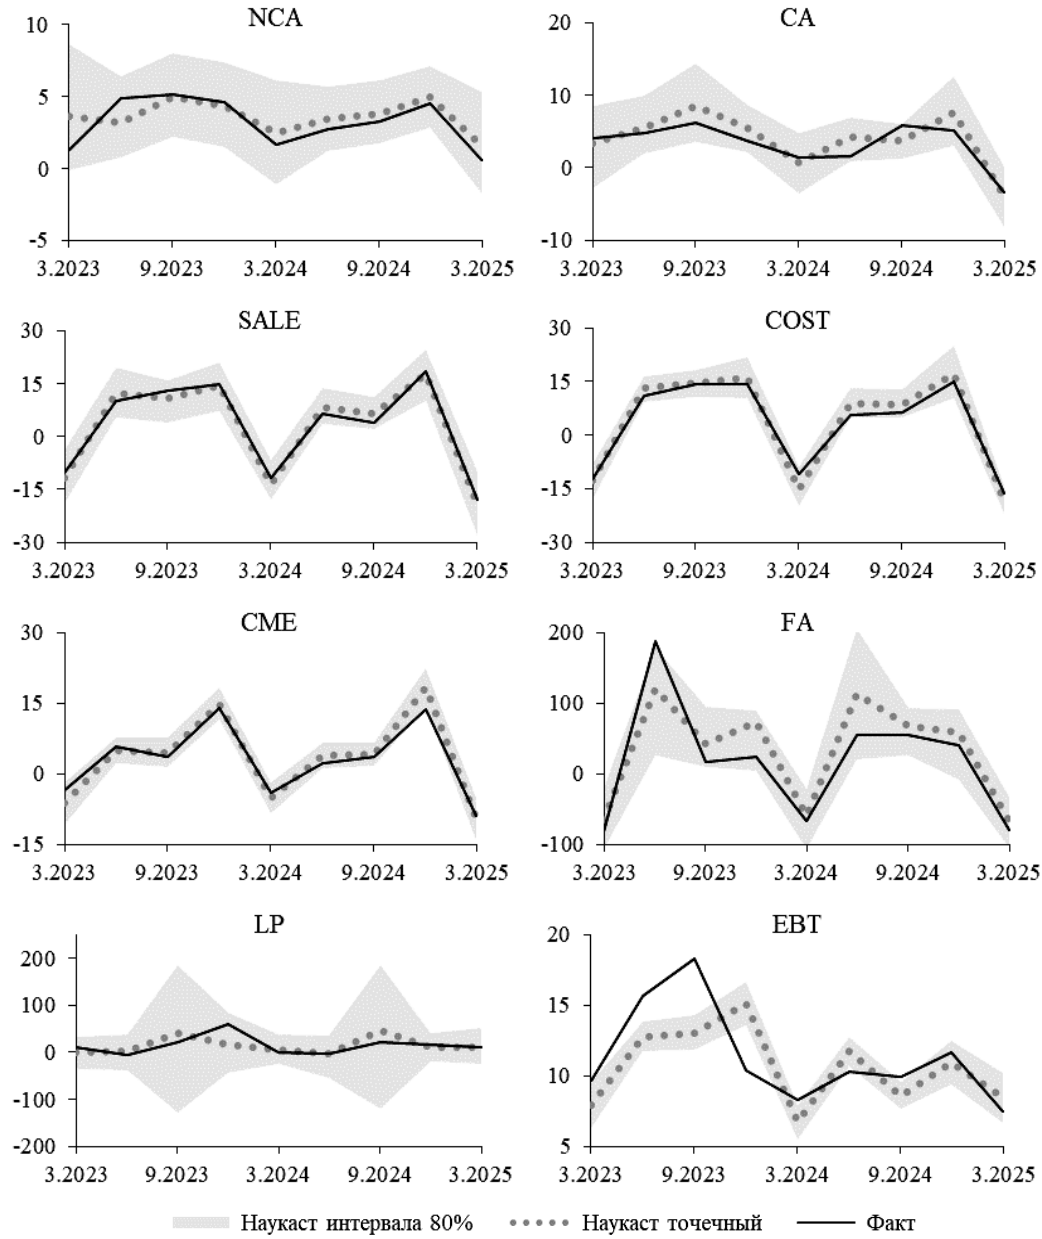


Рис. 1. Наукасты квартальных показателей для экономики в целом, %

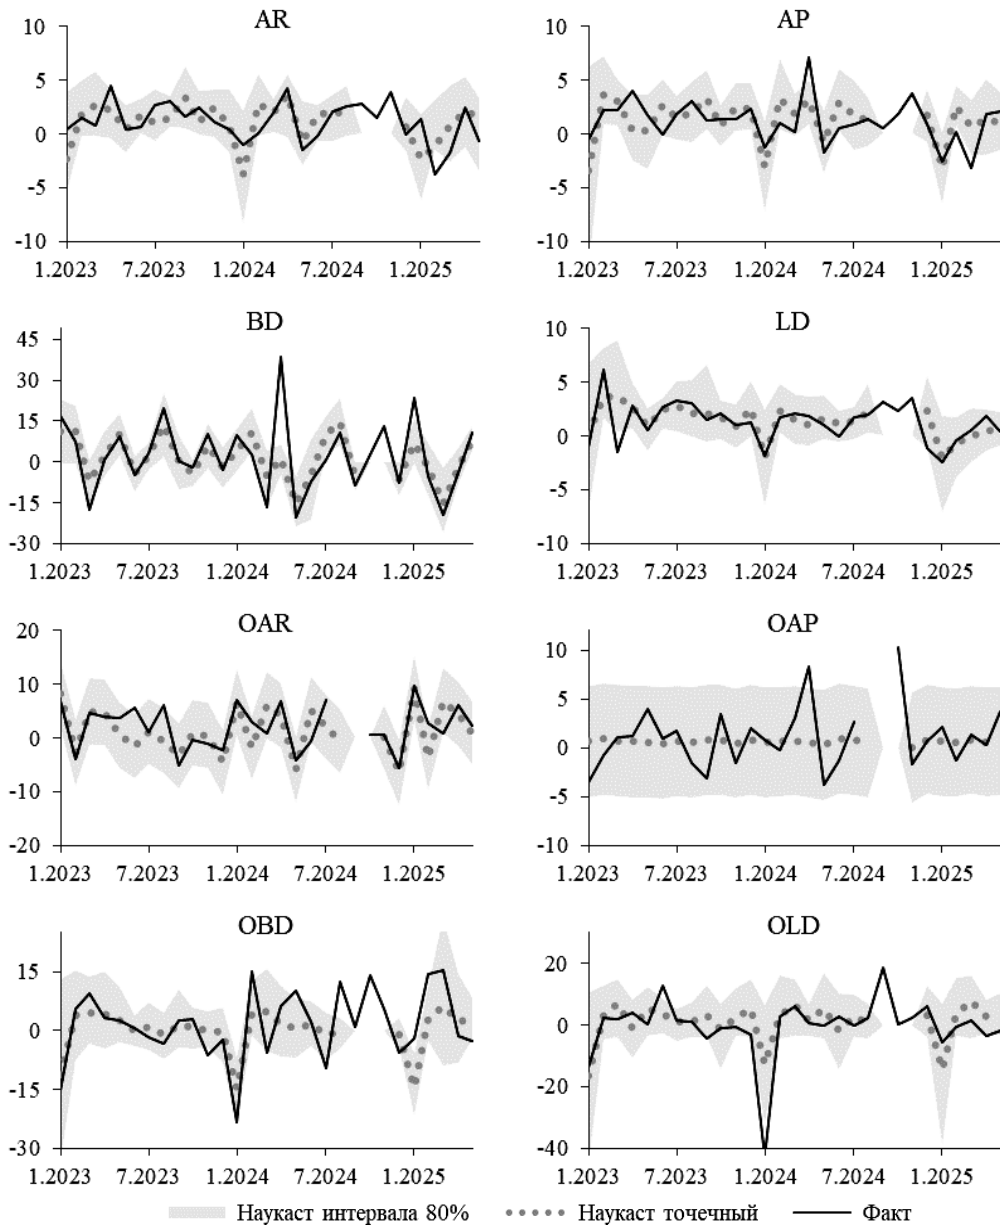


Рис. 2. Наукасты месячных показателей для экономики в целом, %

В завершение отметим, что выбранный для псевдовневыборочных наукастов временной интервал охватывает 2023 г., переходный период восстановления экономики на фоне продолжения геополитического конфликта, и более стабильные 2024–2025 гг. Судя по графикам, выбранные модели могут как недооценивать, так и переоценивать силу па-

дения и роста целевых показателей без каких-либо явных тенденций, при этом они, как правило, производят адекватные прогнозы на всем тестовом периоде, что говорит об их практической пользе для наукастинга финансовых показателей, в том числе в неспокойные моменты.

Также интересно, что, согласно дополнительным расчетам, в «кризисный» период 2023 г. оптимальные модели зачастую демонстрируют более качественные результаты по критерию RMSE для точечных (средних) наукастов, чем в 2024 г. – такая ситуация наблюдается у 10 из 16 целевых переменных на уровне экономики в целом. То же самое характерно и в случае авторегрессионной модели для тех же показателей.

На рис. 3 отражена динамика метрики RMSE точечных (средних) наукастов целевых переменных по экономике в целом, построенных по лучшим моделям (см. табл. П6 в Приложении), для периода 2023 г. и 2024 г.

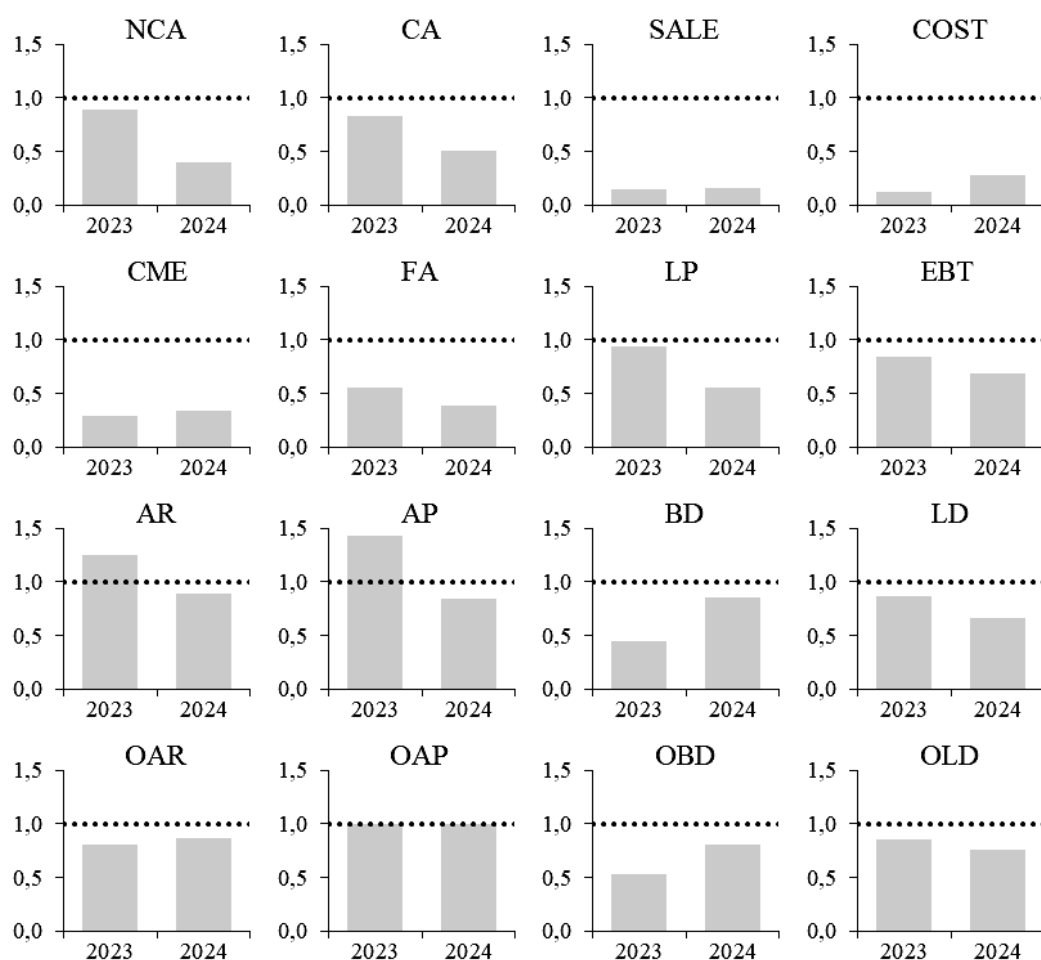


Рис. 3. RMSE наукастов по лучшей модели относительно RMSE модели AR(1) для экономики в целом в различные периоды

Значения нормированы на RMSE бенчмарка AR(1) за соответствующие временные интервалы. Заметим, что подобранные модели превосходят авторегрессию в оба периода для 13 переменных из 16 (критерий составляет менее 1), а в относительно спокойный 2024 г. они производят более точные наукасты, чем однофакторный бенчмарк, во всех случаях, кроме показателя прироста просроченной кредиторской задолженности (OAP), для которого AR(1) является оптимальной моделью. Так, можно предположить, что прогнозная сила используемых предикторов достаточно велика и проявляется преимущественно в более стабильное для экономики время¹⁰. Тем не менее для приростов дебиторской и кредиторской задолженности (AR, AP) авторегрессия дает более точные наукасты на 2023 г., чем лучшие модели. Вероятно, это связано с повышенным уровнем неопределенности в переходные периоды, который в дальнейшем можно частично учесть в уравнениях моделей, например, через добавление индекса геополитического риска. Еще одной возможной причиной низкого качества наукастов, построенных для данных долговых показателей, являются отсрочки платежей, часто предоставляемые предприятиям в кризисные для экономики моменты, и иные специфичные поддерживающие меры, которые трудно поддаются моделированию.

4.2. Предельные эффекты от предикторов

В табл. 6 представлены предельные эффекты от ключевых предикторов, которые отражают, на сколько процентных пунктов изменится точечный (средний) наукаст целевой переменной при увеличении интересующего предиктора на 1 при прочих равных. Значения взяты из лучших моделей для финансовых показателей по экономике в целом (см. табл. П6 в Приложении), которые обучались на последней тренировочной выборке по апрель 2025 г. (IV квартал 2024 г.). Для квантильных регрессий рассматривается средний по квантилям коэффициент¹¹. В случае квантильной нейронной сети предельные эффекты непостоянны. Они зависят от точки, в которой находится интересующий предиктор и все остальные предикторы, поэтому эффекты усредняются не только по квантилям, но и по возможным значениям объясняющих переменных. Стоит иметь в виду, что в рамках квантильных моделей предикторы могут сильно влиять на хвосты условного распределения целевого показателя, оказывая лишь незначительный эффект на его условное среднее.

В числе рассматриваемых индикаторов – общий и отраслевые индексы производства в приростах (IP_{ALL} , IP_{SH} , IP_{DPI} , IP_{OP} , IP_{STR} , IP_{TR}), общая и отраслевая инфляция (CPI , PPI_{ALL} , PPI_{SH} , PPI_{DPI} , PPI_{OP} , PPI_{STR} , PPI_{TR}), прирост эффективного курса рубля (ER), прирост мировой цены на нефть (OIL) и абсолютное изменение процентной ставки (R). Если для одной целевой переменной имеются предельные эффекты от нескольких предикторов из одной группы, в таблицу включается показатель с наибольшим по модулю эффектом. Отметим, что индикаторы из одной группы практически всегда влияют на прогноз однонаправленно.

¹⁰ Эффект может быть несколько переоценен ввиду того, что при построении наукастов на 2024 г. модели обучаются на более объемном массиве данных за счет схемы расширяющегося окна, а это способствует улучшению прогнозных свойств.

¹¹ Если предиктор отсутствует в уравнении для какого-либо квантиля (в результате отбора с помощью алгоритма LASSO), коэффициент при нем полагается нулевым в данном уравнении.

Таблица 6.

**Влияние предикторов на точечные наукасты целевых показателей
для экономики в целом по лучшим моделям**

Предикторы	Прирост индекса производства	Внутренняя инфляция	Прирост валютного курса (ER)	Прирост цены на нефть (OIL)	Изменение процентной ставки (R)
NCA	0,076 (IP _{OP})	0,040 (PPI _{DPI})	0,077	0,067	0,086
CA	0,150 (IP _{DPI})	0,267 (PPI _{OP})	-0,177	0,053	0,135
SALE	0,822 (IP _{ALL})	1,000 (PPI _{ALL})	-0,182	0,133	-1,397
COST	0,675 (IP _{ALL})	0,840 (PPI _{ALL})	-0,157	0,091	-
CME	-	-	-	-	-
FA	-	-	-	-	-
LP	-	4,402 (CPI)	2,047	-0,415	7,442
EBT	-	-	-	-	-
AR	-	0,164 (PPI _{ALL})	-0,069	0,017	-
AP	-0,039 (IP _{OP})	0,790 (CPI)	-0,029	0,040	0,575
BD	-0,257 (IP _{ALL})	1,050 (PPI _{OP})	-0,239	0,137	0,988
LD	-0,046 (IP _{ALL})	0,565 (CPI)	-0,220	-0,024	0,185
OAR	-0,262 (IP _{ALL})	-	-	-	-
OAP	-	-	-	-	-
OBD	5,773 (IP _{DPI})	-1,363 (CPI)	-5,661		3,470
OLD	0,160 (IP _{ALL})	-0,336 (CPI)	0,002	-0,088	-

Примечание: пропуски означают, что предикторы не входят в уравнения лучшей модели; статистическая значимость оценок не приводится, так как для квантильных регрессий и квантильных нейронных сетей отсутствуют стандартные ошибки.

Исходя из табл. 6, предельные эффекты в целом имеют ожидаемые знаки. Наукасты приростов активов и выручки увеличиваются с ускорением роста уровня производства (при экономическом подъеме), а долговых показателей – снижаются. При этом практически все переменные положительно связаны с внутренней инфляцией. Более быстрое ослабление рубля¹², как правило, оказывает положительное влияние на прогнозные значения (общие активы и выручка от продаж растут сильнее за счет более благоприятных условий для компаний, ориентированных на экспорт; в то же время из-за ускорения роста издержек на импортные товары компаниям приходится привлекать больше заемных средств и откладывать расчеты с поставщиками). В свою очередь, более сильный рост цен на нефть ведет к увеличению наукастов темпа прироста активов и выручки (за счет экс-

¹² В таблице приводятся предельные эффекты для случая замедления ослабления рубля.

портеров нефти), а также большинства переменных общей задолженности. Прогнозные значения прироста процентных расходов и долговых показателей логичным образом положительно связаны с более жестким повышением процентной ставки.

5. Заключение

В настоящей работе были протестированы прогнозные свойства моделей для наукастинга совокупных финансовых показателей российских организаций по группам «активы», «доходы и расходы», «финансовое состояние и расчеты». Рассматривалось 16 целевых переменных для 6 секторов экономики. Актуальность исследования была обусловлена задержкой в публикации официальной статистики по выбранным индикаторам. В качестве потенциальных объясняющих переменных были взяты макроэкономические и финансовые показатели, такие как прирост индекса производства, инфляция, прирост мировых цен на сырьевые товары, изменения процентной ставки, прирост индекса МосБиржи и др., а также отраслевые индикаторы: изменение индекса предпринимательской уверенности, опросные оценки динамики выпуска и прибыли. Для отбора предикторов применялся алгоритм LASSO-регрессии.

Особое внимание уделялось построению интервальных прогнозных значений, которые дают представление о рисках, ассоциированных с той или иной целевой переменной. В качестве инструментов для наукастинга рассматривались многофакторная линейная и квантильная регрессии, а также квантильная нейронная сеть на базе многослойного перцептрона. Последние два подхода позволяют моделировать линейную и нелинейную связь между квантилями рассматриваемого показателя и выбранными объясняющими переменными. Бенчмарками выступали линейная авторегрессия порядка 1 и динамическая факторная модель. В рамках анализа была выбрана лучшая модель для каждого целевого показателя по различным отраслям.

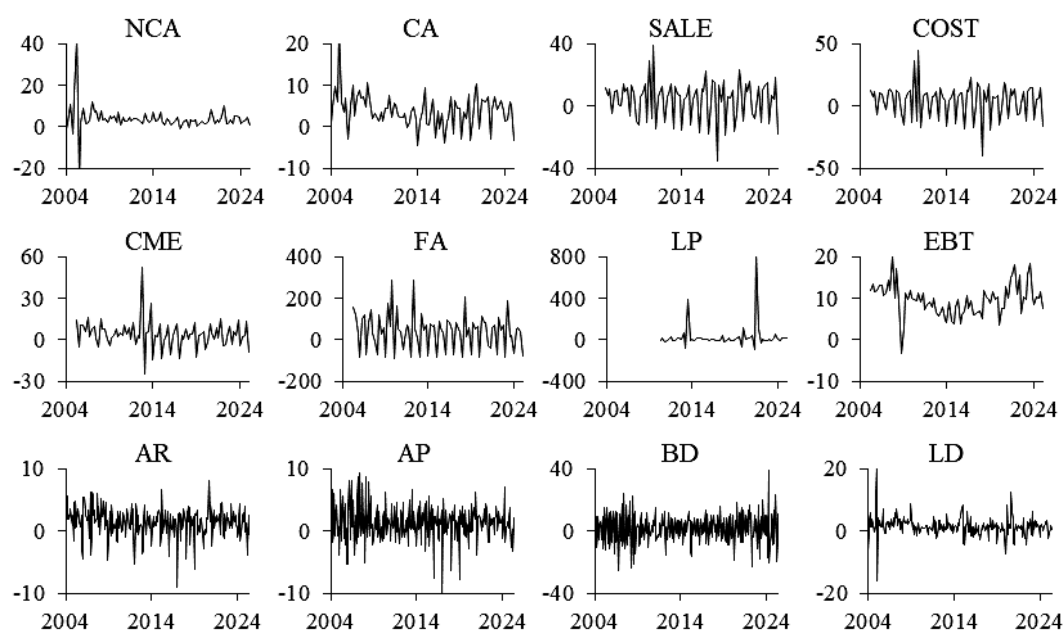
При рассмотрении приростов показателей внеоборотных и оборотных активов, выручки от продажи продукции, выручки от продажи основных средств, себестоимости продукции, коммерческих и управленческих расходов, а также общей и просроченной задолженности по кредитам, общей задолженности по платежам в бюджет удалось получить наиболее точные наукасты. Подобранные модели, как правило, дают стабильно качественные прогнозы как в кризисные, так и в более спокойные периоды. Предложенный модельный аппарат может использоваться органами власти с целью получения оперативной статистики по совокупным финансовым показателям предприятий как на макроуровне, так и в разрезе отдельных секторов экономики. Процедура позволяет строить наукасты с задержкой до одного месяца против задержки около двух месяцев в публикации официальной статистики. Эти данные могут быть полезны при разработке общих и адресных мер социально-экономической политики по стимулированию экономики и поддержке бизнеса, а также при оценке долговой нагрузки компаний и планировании бюджетных поступлений.

Проведенные эксперименты показали, что модель квантильной нейронной сети с предикторами, подобранными на основе алгоритма LASSO, лидирует по метрикам качества как интервальных, так и точечных наукастов для большинства целевых переменных. В свою очередь, квантильная регрессия, как правило, дает второй по рангу результат. Однако стоит иметь в виду, что подход квантильных моделей не является универсальным.

Как оказалось, при рассмотрении некоторых финансовых индикаторов не требуется моделирование сложных нелинейных зависимостей между прогнозируемой переменной и ее предикторами. В таких случаях предпочтение отдается более простым методам – динамической факторной модели и линейной LASSO-регрессии. Тем не менее можно заключить, что квантильная нейронная сеть и квантильная регрессия выступают важным дополнением традиционного подхода к решению задач прогностической аналитики, который предполагает использование моделей для условного среднего. Данные инструменты должны давать ощутимое преимущество в ситуациях, когда нарушается предположение о нормальном распределении значений целевого показателя, что крайне часто можно встретить при работе с реальными данными. Корректное моделирование функции распределения позволяет получить и более качественные интервальные прогнозы, и более точные оценки среднего.

Существенным ограничением проведенного исследования выступает использование моделей, которые не задействуют данные смешанной частоты. В свою очередь, такие инструменты, как MIDAS и MFBVAR, хорошо зарекомендовавшие себя во многочисленных российских исследованиях по наукастингу ВВП, могли бы значительно улучшить качество наукастов для квартальных финансовых показателей. Расширение модельного аппарата может быть реализовано в рамках дальнейших разработок по данной теме.

Приложение.






Рис. 11. Временные ряды целевых показателей в целом по экономике, %

Таблица П1.

**Предикторы, которые часто отбираются алгоритмами LASSO
для экономики в целом**

	Среднее	Квантиль 20%	Квантиль 50%	Квантиль 80%
NCA	ORT, U, CPI, PPI _{DPI} , ER, OIL, GAS, WHT, CNF _{TR} , OUT _{DPI} , IMX, M, CRT, R	IP _{OP} , ORT, FO _S , CRT	IP _{ALL} , IP _{OP} , ER, GAS, WHT, CNF _{OP} , OUT _{DPI} , M, CRT, R	PPI _{DPI} , ER, GAS, CNF _{STR} , OUT _{OP} , IMX, R
CA	IP _{ALL} , IP _{DPI} , ORT, U, CPI, ER, OIL, GAS, CNF _{DPI} , OUT _{DPI} , IMX, M	IP _{ALL} , IP _{DPI} , IP _{OP} , ER, OIL, OUT _{DPI} , FO _{STR} , IMX, M, CRT	IP _{DPI} , ORT, U, ER, OIL, GAS, M	IP _{ALL} , ORT, ER, OIL, GAS, CNF _{TR} , M, R
SALE	IP _{ALL} , IP _{OP} , ORT, PPI _{OP} , ER, WHT, OUT _{DPI}	IP _{ALL} , IP _{OP} , ORT, PPI _{OP} , PPI _{OP} , ER, WHT, OUT _{DPI}	IP _{ALL} , IP _{OP} , ORT, PPI _{OP} , ER, OIL, OUT _{DPI} , PRF _{TR} , M	IP _{ALL} , IP _{SH} , ORT, PPI _{OP} , OIL, CNF _{OP} , OUT _{DPI} , R
COST	IP _{ALL} , IP _{OP} , ORT, PPI _{OP} , WHT, OUT _{DPI}	IP _{ALL} , IP _{OP} , ORT, PPI _{OP} , WHT, IMX	IP _{ALL} , IP _{OP} , ORT, PPI _{DPI} , PPI _{OP} , ER, OIL, WHT, PRF _{TR} , M	IP _{ALL} , IP _{DPI} , IP _{OP} , ORT, PPI _{OP} , ER, OIL, WHT, CNF _{OP} , CNF _{TR}
CME	IP _{ALL} , ORT, CNF _{DPI} , CNF _{TR}	IP _{ALL} , ORT, CNF _{OP} , CNF _{TR} , M, CRT	IP _{ALL} , ORT, PPI _{DPI} , CNF _{OP} , CNF _{TR} , FO _{STR} , IMX, M, CRT	IP _{ALL} , ORT, PPI _{ALL} , CNF _{DPI} , CNF _{OP} , IMX, M
FA	OUT _{DPI} , OUT _{OP}	PPI _{DPI} , FO _{STR} , IMX	WHT, OUT _{DPI} , IMX	IP _{OP} , ORT, FO _{STR} , CRT
LP	IP _{DPI} , U, GAS, WHT, OUT _{OP} , FO _{STR} , IMX, M, R	PPI _{OP} , GAS, WHT, M	CNF _{DPI} , OUT _{DPI} , FO _{STR} , M, R	GAS, CNF _{STR} , M
EBT	IP _{OP} , ORT, CPI, ER, OIL, WHT, CNF _{STR} , CNF _{TR} , OUT _{DPI} , FO _{STR} , IMX, M, CRT, R	CPI, ER, OIL, FO _{STR} , M, CRT, R	IP _{OP} , PPI _{OP} , WHT, CNF _{STR} , IMX, M, CRT	IP _{OP} , PPI _{OP} , GAS, WHT

Окончание табл. П1.

	Среднее	Квантиль 20%	Квантиль 50%	Квантиль 80%
AR	CPI, PPI _{ALL} , PPI _{SH} , ER, GAS, OUT _{DPI} , OUT _{OP} , IMX, CRT, R	PPI _{ALL} , PPI _{OP} , ER, GAS, OUT _{OP} , R	IP _{OP} , PPI _{OP} , ER, OIL, GAS, OUT _{DPI} , OUT _{OP} , IMX, CRT, R	IP _{OP} , U, PPI _{OP} , ER, OUT _{OP} , IMX, M
AP	PPI _{OP} , OIL, WHT, OUT _{DPI} , OUT _{OP} , IMX, M, CRT, R	IP _{OP} , CPI, WHT, OUT _{OP} , IMX, M, CRT, R	IP _{OP} , PPI _{OP} , ER, CNF _{OP} , OUT _{DPI} , IMX, M, CRT, R	OIL, OUT _{DPI} , OUT _{OP} , IMX, M, CRT, R
BD	IP _{ALL} , IP _{SH} , IP _{OP} , PPI _{DPI} , PPI _{OP} , ER, OIL, GAS, WHT, CNF _{DPI} , OUT _{DPI} , OUT _{OP} , IMX, M, CRT, R	IP _{OP} , PPI _{OP} , ER, OIL	IP _{OP} , PPI _{OP} , ER, OIL, M, CRT, R	IP _{ALL} , PPI _{OP} , OIL, CNF _{OP} , M, CRT, R
LD	PPI _{DPI} , ER, OIL, CNF _{OP} , OUT _{DPI} , OUT _{OP} , IMX, CRT, R	ER, OUT _{OP} , IMX	ORT, ER, OIL, CNF _{OP} , OUT _{DPI} , OUT _{OP} , IMX, CRT	ER, OIL, OUT _{OP} , IMX, M, CRT, R
OAR	ORT, OUT _{DPI} , M	ORT, GAS, OUT _{DPI} , IMX, M	IP _{ALL} , IP _{OP} , ORT, CPI, ER, OUT _{DPI} , IMX, M	IP _{ALL} , IP _{OP} , ORT, U, CPI, OUT _{DPI} , IMX, R
OAP	U, CPI, PPI _{DPI} , PPI _{OP} , OIL, WHT, CNF _{DPI} , OUT _{DPI} , OUT _{OP} , IMX, M, R	CPI, OIL, GAS, OUT _{DPI} , OUT _{OP} , IMX, M	CPI, PPI _{DPI} , CNF _{DPI} , OUT _{DPI} , IMX, M, CRT	CPI, PPI _{DPI} , CNF _{DPI} , OUT _{DPI} , IMX, M
OBD	CPI	GAS, OUT _{OP} , M, CRT	U, GAS, CNF _{OP} , OU- T _{OP} , M, CRT	U, GAS, CNF _{OP} , OUT _{OP} , M, CRT
OLD	IP _{OP} , CNF _{OP}	IP _{ALL} , CPI, OIL, GAS, CNF _{OP} , IMX	IP _{ALL} , OIL, CNF _{DPI} , CNF _{OP} , IMX, CRT	IP _{OP} , ORT, WHT, CNF _{DPI} , CNF _{OP} , CRT

Примечание: в список включались переменные, отобранные в рамках более чем половины обучающих выборок при построении псевдовневыборочных наукастов; при формировании списков не учитывались выбранные сезонные дамми и лаги целевых переменных.

Таблица П2.

Спецификация нейронной сети для квартальных показателей

Сектор	Параметр	NCA	CA	SALE	COST	CME	FA	LP	EBT
SH	$\phi(*)$	R	T	R	R	R	R	T	R
	K	3	3	3	3	2	2	2	1
DPI	$\phi(*)$	R	R	R	R	R	T	T	R
	K	1	3	1	1	1	1	3	2

Окончание табл. П2.

Сектор	Параметр	NCA	CA	SALE	COST	CME	FA	LP	EBT
OP	$\phi(*)$	R	R	T	T	R	R	R	R
	K	1	1	1	2	1	1	1	2
STR	$\phi(*)$	R	R	R	T	R	T	R	T
	K	3	1	2	1	1	2	5	4
TR	$\phi(*)$	R	R	R	T	T	R	R	R
	K	2	2	1	2	1	1	2	4
ALL	$\phi(*)$	T	R	R	R	R	T	R	R
	K	1	3	2	1	1	1	2	5

Таблица П3.

Спецификация нейронной сети для месячных показателей

Сектор	Параметр	AR	AP	BD	LD	OAR	OAP	OBD	OLD
SH	$\phi(*)$	R	T	T	R	R	T	R	R
	K	3	5	5	2	1	3	1	1
DPI	$\phi(*)$	R	R	T	T	R	R	R	R
	K	3	4	3	3	3	2	3	1
OP	$\phi(*)$	R	R	T	R	R	T	R	R
	K	5	3	1	1	3	3	2	2
STR	$\phi(*)$	R	R	R	R	T	R	R	T
	K	1	2	4	1	1	1	5	1
TR	$\phi(*)$	T	R	T	R	R	T	R	R
	K	4	4	3	1	1	1	1	1
ALL	$\phi(*)$	T	T	R	R	T	R	T	R
	K	2	2	3	2	3	1	4	1

Таблица П4.

**Сравнение качества моделей по метрике MAE
для экономики в целом**

Модель	AR(1)	DFM	LR	QR	QRNN
NCA	1,55	2,40	1,15*	0,85**	0,81***
CA	2,11*	2,12	2,34	2,05**	1,46***
SALE	9,53	2,22**	4,02	2,30*	1,55***
COST	9,76	2,51*	4,42	2,05**	2,03***
CME	5,04	1,58***	1,90**	2,55*	2,63
FA	62,04	34,44	29,83*	27,10**	27,04***
LP	22,45	46,17	64,19	14,98**	11,51***
EBT	2,63**	2,29***	3,02	3,29	2,76*
AR	1,47**	1,70	1,47**	1,59	1,42***
AP	1,43***	2,15	1,62	1,59*	1,51**
BD	9,77	8,61	6,19**	6,21*	5,78***
LD	1,42	1,29	1,07*	0,94**	0,92***
OAR	3,79	3,23	2,71***	2,95**	3,12*
OAP	2,00***	2,68	3,17	2,59*	2,49**
OBD	7,00	5,71**	6,12	6,00*	5,63***
OLD	5,19	4,94*	5,49	4,71**	4,38***

Примечание: метрика MAE рассчитывается на основе точечных наукастов, в рамках квантильных моделей рассматривается прогноз медианного значения; тремя астерисками отмечен наилучший результат, двумя и одним астериском – результат второго и третьего ранга соответственно.

Таблица П5.

**P-value теста Диболда – Мариано на сравнение RMSE моделей против AR(1)
с двусторонней альтернативной гипотезой для экономики в целом**

Модель	DFM	LR	QR	QRNN
NCA	0,000***	0,788	0,044***	0,018***
CA	0,494	0,807	0,401	0,314
SALE	0,016***	0,041***	0,016***	0,014***
COST	0,008***	0,016***	0,006***	0,007***
CME	0,022***	0,038***	0,106**	0,086***

Окончание табл. П5.

Модель	DFM	LR	QR	QRNN
FA	0,025***	0,029***	0,025***	0,023***
LP	0,013***	0,029***	0,518	0,320
EBT	0,317	0,729	0,085***	0,782
AR	0,002***	0,678	0,891	0,651
AP	0,022***	0,908	0,851	0,677
BD	0,968	0,008***	0,015***	0,005***
LD	0,480	0,299*	0,056***	0,195**
OAR	0,176**	0,227*	0,208*	0,206*
OAP	0,055***	0,014***	0,213*	0,281*
OBD	0,178**	0,254*	0,231*	0,130**
OLD	0,272*	0,399	0,299*	0,280*

Примечание: тремя астерисками отмечены случаи отвержения нулевой гипотезы о незначимости различий на уровне значимости 10%, двумя и одним астериском – на уровнях 20% и 30% соответственно.

Таблица П6.
Лучшая модель по метрике RMSE для целевых переменных по секторам

Сектор	SH	DPI	OP	STR	TR	ALL
NCA	DFM	QRNN	QRNN	AR(1)	AR(1)	QR
CA	QRNN	QRNN	LR	QRNN	AR(1)	QRNN
SALE	QRNN	QRNN	DFM	QRNN	QRNN	QRNN
COST	QRNN	QR	QRNN	DFM	QRNN	QR
CME	QRNN	QR	QR	QRNN	DFM	DFM
FA	DFM	QRNN	QR	DFM	DFM	LR
LP	QRNN	QR	AR(1)	QRNN	AR(1)	QRNN
EBT	LR	DFM	DFM	DFM	AR(1)	DFM
AR	QRNN	DFM	QRNN	QRNN	AR(1)	LR
AP	QRNN	QRNN	AR(1)	AR(1)	AR(1)	QRNN
BD	QRNN	QRNN	QRNN	QRNN	QRNN	QRNN
LD	AR(1)	LR	LR	LR	AR(1)	QR
OAR	QRNN	AR(1)	QRNN	AR(1)	DFM	LR
OAP	AR(1)	QRNN	QRNN	QRNN	AR(1)	AR(1)
OBD	AR(1)	QR	QRNN	DFM	LR	QRNN
OLD	LR	QR	QRNN	QRNN	QR	QR

Таблица П7.

**Лучшая модель по метрике CRPS для целевых переменных
по секторам**

Сектор	SH	DPI	OP	STR	TR	ALL
NCA	DFM	QRNN	QRNN	AR(1)	DFM	QR
CA	QRNN	QRNN	QRNN	QRNN	AR(1)	QRNN
SALE	QRNN	QRNN	QRNN	LR	QRNN	QRNN
COST	QRNN	QRNN	QRNN	DFM	QRNN	QR
CME	QRNN	QRNN	QR	QRNN	DFM	DFM
FA	QRNN	QRNN	QR	QRNN	QR	QRNN
LP	QRNN	QRNN	QRNN	DFM	QRNN	QRNN
EBT	LR	QRNN	DFM	QRNN	AR(1)	DFM
AR	QRNN	QRNN	QRNN	QRNN	AR(1)	QRNN
AP	QRNN	QRNN	AR(1)	QRNN	AR(1)	QRNN
BD	QRNN	QRNN	QRNN	QRNN	QRNN	QRNN
LD	AR(1)	QR	QRNN	QRNN	DFM	QRNN
OAR	QRNN	DFM	QRNN	QRNN	DFM	LR
OAP	QR	QRNN	QRNN	QRNN	AR(1)	AR(1)
OBD	LR	QRNN	QRNN	QRNN	AR(1)	QRNN
OLD	LR	QR	QRNN	QRNN	QR	QRNN

Таблица П8.

**Лучшая модель по метрике MAE для целевых переменных
по секторам**

Сектор	SH	DPI	OP	STR	TR	ALL
NCA	DFM	QRNN	QRNN	AR(1)	AR(1)	QRNN
CA	QRNN	QRNN	LR	QRNN	AR(1)	QRNN
SALE	QRNN	LR	QRNN	QRNN	LR	QRNN
COST	QRNN	QR	QRNN	DFM	DFM	QRNN
CME	QRNN	QR	QR	QRNN	DFM	DFM
FA	QRNN	QRNN	QR	QRNN	QRNN	QRNN
LP	QRNN	QRNN	QR	QRNN	AR(1)	QRNN

Окончание табл. П8.

Сектор	SH	DPI	OP	STR	TR	ALL
EBT	LR	DFM	DFM	QRNN	AR(1)	DFM
AR	QRNN	QRNN	QRNN	QRNN	AR(1)	QRNN
AP	QRNN	DFM	AR(1)	AR(1)	AR(1)	AR(1)
BD	QRNN	QRNN	QRNN	QRNN	QRNN	QRNN
LD	AR(1)	LR	LR	QRNN	AR(1)	QRNN
OAR	QRNN	DFM	QRNN	AR(1)	QRNN	LR
OAP	QR	DFM	QRNN	AR(1)	AR(1)	AR(1)
OBD	LR	QRNN	QRNN	QRNN	AR(1)	QRNN
OLD	LR	QRNN	QRNN	QRNN	DFM	QRNN




Рис. П2. Наукасты целевых показателей для сектора «Сельское, лесное хозяйство, охота, рыболовство и рыбоводство», %

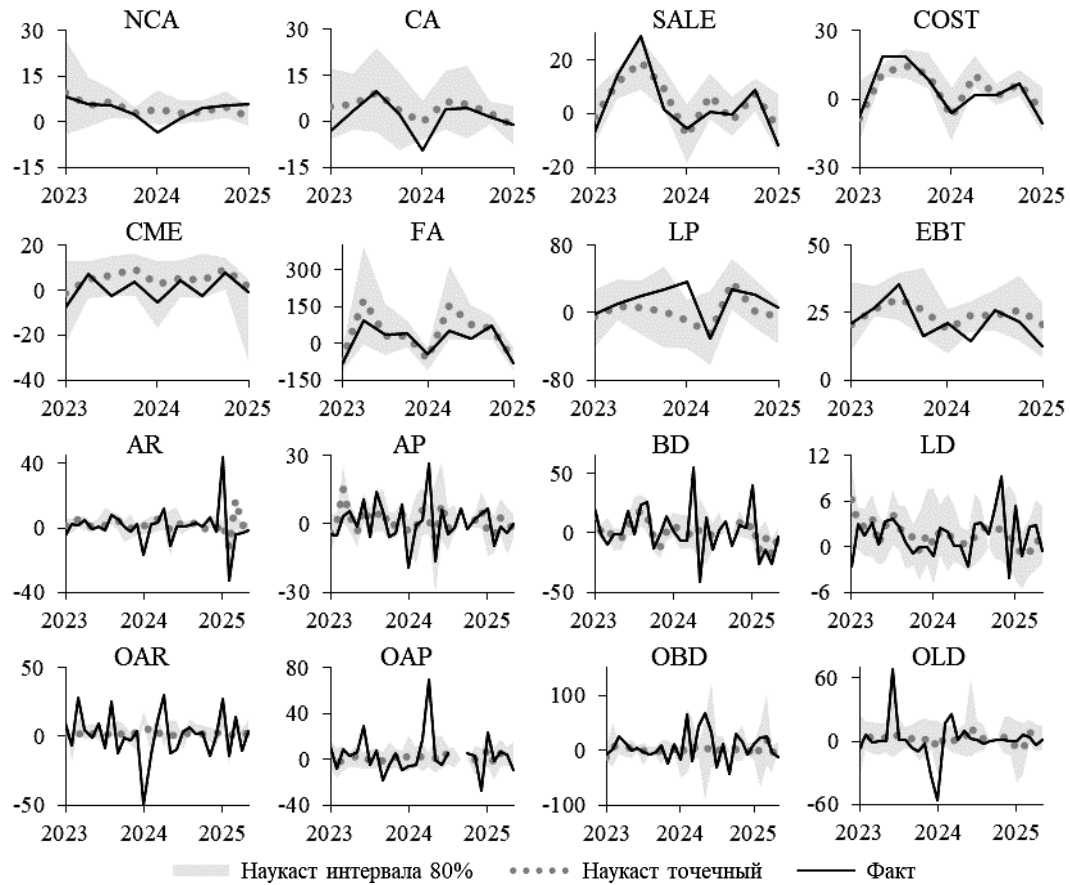


Рис. 13. Наукасты целевых показателей для сектора «Добыча полезных ископаемых», %




Рис. 14. Наукасты целевых показателей для сектора «Обрабатывающие производства», %




Рис. П5. Наукасты целевых показателей для сектора «Строительство», %

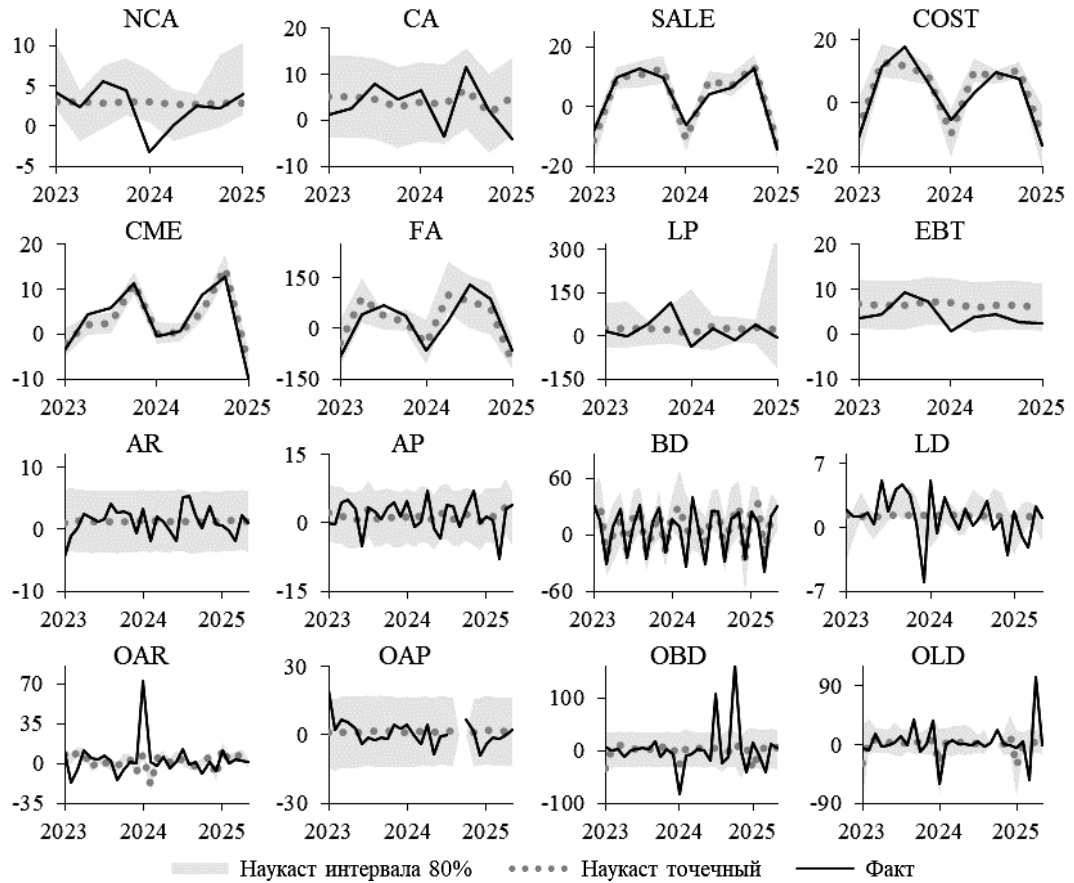


Рис. 16. Наукасты целевых показателей для сектора «Торговля оптовая и розничная, ремонт автотранспортных средств и мотоциклов», %

* *

*

СПИСОК ЛИТЕРАТУРЫ

Гареев М.Ю., Полбин А.В. Наукастинг: оценка изменения ключевых макроэкономических показателей с использованием методов машинного обучения // Вопросы экономики. 2022. № 8. С. 133–157. <https://doi.org/10.32609/0042-8736-2022-8-133-157>

- Зубарев А.В., Рыбак К.С.* Наукакстинг ВВП: динамическая факторная модель и официальные прогнозы // *Экономическое развитие России*. 2021. Т. 28. № 12. С. 34–40.
- Зубарев А., Ломоносов Д., Рыбак К.* Оценка влияния глобальных шоков на российскую экономику и наукакстинг ВВП в рамках факторной модели // *Деньги и Кредит*. 2022. Т. 81. № 2. С. 49–78.
- Казакова М.В., Фокин Н.Д.* Тестирование прогнозных свойств различных подходов к интервальному прогнозированию (на примере инфляции в России) // *Вопросы статистики*. 2024. Т. 31. № 5. С. 23–40. <https://doi.org/10.34023/2313-6383-2024-31-5-23-40>
- Крыжановский О., Могилат А., Шувалова Ж., Гвоздев Д.* Использование нейросетей LSTM для наукакстинга и прогнозирования ВДС отраслей промышленности // *Деньги и Кредит*. 2025. Т. 84. № 1. С. 93–104.
- Ляхнова М., Коленко Ю.* Оценка разрыва выпуска России по данным мониторинга предприятий // *Деньги и Кредит*. 2024. Т. 83. № 2. С. 26–53.
- Майорова К., Фокин Н.* Наукакстинг темпов роста стоимостных объемов экспорта и импорта России по товарным группам // *Деньги и Кредит*. 2021. Т. 80. № 3. С. 34–48. <https://doi.org/10.31477/gjmf.202103.34>
- Макеева Н.М., Станкевич И.П.* Наукакстинг элементов использования ВВП России // *Экономический журнал ВШЭ*. 2022. Т. 26. № 4. С. 598–622. <https://doi.org/10.17323/1813-8691-2022-26-4-598-622>
- Макеева Н.М., Станкевич И.П., Любайкин Н.С.* Наукакстинг макроэкономических показателей экономики России в условиях неопределенности: помогает ли учет новостного фона? // *Вопросы экономики*. 2024. № 3. С. 120–142. <https://doi.org/10.32609/0042-8736-2024-3-120-142>
- Макеева Н.М.* Влияние версии ревизии официальной статистики на точность моделей наукакстинга макроэкономических показателей России // *Прикладная эконометрика*. 2025. Т. 79. С. 27–49. <https://doi.org/10.22394/1993-7601-2025-79-27-49>
- Полбин А.В., Шумилов А.В.* Наукакстинг и прогнозирование ВВП России и его компонентов с помощью квантильных моделей // *Прикладная эконометрика*. 2025. Т. 79. С. 5–26. <https://doi.org/10.22394/1993-7601-2025-79-5-26>
- Рыбак К.С.* Анализ важности глобальных факторов для наукакстинга ВВП // *Экономическое развитие России*. 2023. Т. 3. № 12. С. 18–22.
- Станкевич И.П.* Применение MIDAS-моделей с марковским переключением для наукакстинга ВВП и его компонентов // *Прикладная эконометрика*. 2023. Т. 70. С. 122–143. <https://doi.org/10.22394/1993-7601-2023-70-122-143>
- Фокин Н.Д.* Наукакстинг и прогнозирование основных российских макроэкономических показателей с помощью MFVAR-модели // *Экономическая политика*. 2023. Т. 18. № 3. С. 110–135. <https://doi.org/10.18288/1994-5124-2023-3-110-135>
- Adrian T., Boyarchenko N., Giannone D.* Vulnerable Growth // *The American Economic Review*. 2019. Vol. 109. № 4. P. 1263–1289. <https://doi.org/10.1257/aer.20161923>
- Cannon A.* Quantile Regression Neural Networks: Implementation in R and Application to Precipitation Downscaling // *Computers & Geosciences*. 2011. Vol. 37. № 9. P. 1277–1284. <https://doi.org/10.1016/j.cageo.2010.07.005>
- Carriero A., Clark T.E., Marcellino M.* Nowcasting Tail Risks to Economic Activity with Many Indicators // Working Paper № 20–13R2. Federal Reserve Bank of Cleveland, 2020. <https://doi.org/10.26509/frbc-wp-202013r2>
- Carriero A., Clark T.E., Marcellino M.* Specification Choices in Quantile Regression for Empirical Macroeconomics // Working Paper № 22–25. Federal Reserve Bank of Cleveland, 2022. <https://doi.org/10.26509/frbc-wp-202225>
- He Y., Li H.* Probability Density Forecasting of Wind Power Using Quantile Regression Neural Network and Kernel Density Estimation // *Energy Conversion and Management*. 2018. Vol. 164. № 15. P. 374–384. <https://doi.org/10.1016/j.enconman.2018.03.010>
- He Y., Qin Y., Wang S., Wang X., Wang C.* Electricity Consumption Probability Density Forecasting Method Based on LASSO-Quantile Regression Neural Network // *Applied Energy*. 2019. Vol. 233–234. P. 565–575. <https://doi.org/10.1016/j.apenergy.2018.10.061>

He Y., Xu Q., Wan J., Yang S. Short-Term Power Load Probability Density Forecasting Based on Quantile Regression Neural Network And Triangle Kernel Function // *Energy*. 2016. Vol. 114. № 1. P. 498–512. <https://doi.org/10.1016/j.energy.2016.08.023>

Koenker R. *Quantile Regression*. Cambridge University Press, 2005. <https://doi.org/10.1017/CBO9780511754098>

Mitchell J., Poon A., Mazzi G.L. Nowcasting Euro Area GDP Growth Using Bayesian Quantile Regression // *Essays in Honor of M. Hashem Pesaran: Prediction and Macro Modeling* (eds. A. Chudik et al.). Emerald Group Publishing Limited, 2022. Ch. 3. <https://doi.org/10.1108/S0731-90532021000043A004>

Taylor J.W. A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns // *Journal of Forecasting*. 2000. Vol. 19. № 4. P. 299–311. [https://doi.org/10.1002/1099-131X\(200007\)19:4<299::AID-FOR775>3.0.CO;2-V](https://doi.org/10.1002/1099-131X(200007)19:4<299::AID-FOR775>3.0.CO;2-V)

Nowcasting Aggregate Financial Indicators of Russian Enterprises

Alexandra Chudaeva

Institute for Research on Socio-Economic Transformations and Financial Policy
of the Financial University under the Government of the Russian Federation.
49/2, Leningradsky Ave., Moscow, 125167, Russian Federation.
E-mail: sasha.chudaeva@yandex.ru

The research is devoted to constructing models that are able to nowcast (assess the current state) aggregate financial indicators of Russian organizations, the official statistics on which are becoming available with a delay. Sixteen target variables, which include profits of enterprises, current and non-current assets, revenue, expenses of various categories, indicators of total and overdue debt, are considered across various sectors: agriculture, mining, manufacturing, construction, trade and the whole economy. Quickly published economic and financial indicators of the Russian economy, including ones that take into account industry specifics, are used as predictors. Attention is focused on constructing interval (probabilistic) nowcasts that reflect a more complete picture of variables' dynamics and support risk assessment. Despite the abundance of domestic studies on the nowcasting of macroeconomic indicators, including the ones involving probabilistic forecasting methods, the problem of prompt assessment of aggregated financial indicators has not been previously addressed. Linear regression, quantile regression, and quantile regression neural network are used as the forecasting tools. Predictors are selected using linear and quantile LASSO-regressions. The models are compared with first-order autoregression and dynamic factor model. The optimal model is selected for each target variable after testing on historical data. According to the results obtained, different tools should be used to produce nowcasts of selected indicators. Nevertheless, neural network, which has the advantage of modeling complex nonlinear dependencies, turns out to be the best approach to interval

Alexandra Chudaeva – intern-researcher.

and point nowcasting for the largest number of targets. The constructed models can be used by public authorities to obtain prompt data on financial indicators and develop timely measures to support Russian enterprises, as well as in the framework of tasks such as assessing the debt burden and financial stability of business, planning budget revenues and tax policy.

Key words: nowcasting; financial indicators; Russian enterprises; industries; sectors; density nowcasts; quantile regression; neural network; LASSO-regression.

JEL Classification: C22, C53, E27, G30.

The article is based on the results of research carried out at the expense of the Scientific Fund of the Financial University.

* *
*

References

- Adrian T., Boyarchenko N., Giannone D. (2019) Vulnerable Growth. *The American Economic Review*, 109, 4, pp. 1263–89. <https://doi.org/10.1257/aer.20161923>
- Cannon A. (2011) Quantile Regression Neural Networks: Implementation in R and Application to Precipitation Downscaling. *Computers & Geosciences*, 37, 9, pp. 1277–1284. <https://doi.org/10.1016/j.cageo.2010.07.005>
- Carriero A., Clark T.E., Marcellino M. (2020) *Nowcasting Tail Risks to Economic Activity with Many Indicators*. Working Paper no 20–13R2. Federal Reserve Bank of Cleveland. <https://doi.org/10.26509/frbc-wp-202013r2>
- Carriero A., Clark T.E., Marcellino M. (2022) *Specification Choices in Quantile Regression for Empirical Macroeconomics*. Working Paper no 22–25. Federal Reserve Bank of Cleveland. <https://doi.org/10.26509/frbc-wp-202225>
- Fokin N.D. (2023) Nowcasting and Forecasting Key Russian Macroeconomic Variables With the MFBVAR Model. *Economic Policy*, 18, 3, pp. 110–135. (In Russ.) <https://doi.org/10.18288/1994-5124-2023-3-110-135>
- Gareev M.Y., Polbin A.V. (2022) Nowcasting Russia's key Macroeconomic Variables Using Machine Learning. *Voprosy Ekonomiki*, 8, pp. 133–157. (In Russ.) <https://doi.org/10.32609/0042-8736-2022-8-133-157>
- He Y., Li H. (2018) Probability Density Forecasting of Wind Power Using Quantile Regression Neural Network and Kernel Density Estimation. *Energy Conversion and Management*, 164, 15, pp. 374–384. <https://doi.org/10.1016/j.enconman.2018.03.010>
- He Y., Qin Y., Wang S., Wang X., Wang C. (2019) Electricity Consumption Probability Density Forecasting Method Based on LASSO-Quantile Regression Neural Network. *Applied Energy*, 233–234, pp. 565–575. <https://doi.org/10.1016/j.apenergy.2018.10.061>
- He Y., Xu Q., Wan J., Yang S. (2016) Short-Term Power Load Probability Density Forecasting Based on Quantile Regression Neural Network and Triangle Kernel Function. *Energy*, 114, 1, pp. 498–512. <https://doi.org/10.1016/j.energy.2016.08.023>
- Kazakova M.V., Fokin N.D. (2024) Testing Forecasting Properties of Different Approaches to Interval Forecasting (Using the Example of Inflation in Russia). *Voprosy Statistiki*, 31, 5, pp. 23–40. (In Russ.) <https://doi.org/10.34023/2313-6383-2024-31-5-23-40>

- Koenker R. (2005) *Quantile Regression*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511754098>
- Kryzhanovskiy O., Mogilat A., Shuvalova Zh., Gvozdev D. (2025) Using LSTM Neural Networks for Nowcasting and Forecasting GVA of Industrial Sectors. *Russian Journal of Money and Finance*, 84, 1, pp. 93–104.
- Lyakhnova M., Kolenko Y. (2024) Nowcasting the Output Gap in Russia Using Enterprise Monitoring Data. *Russian Journal of Money and Finance*, 83, 2, pp. 26–53.
- Maierova K., Fokin N. (2021) Nowcasting Growth Rates of Russia's Export and Import by Commodity Groups. *Russian Journal of Money and Finance*, 80, 3, pp. 34–48. <https://doi.org/10.31477/rjmf.202103.34>
- Makeeva N., Stankevich I. (2022) Nowcasting of the Components of Russian GDP. *HSE Economic Journal*, 26, 4, pp. 598–622. (In Russ.) <https://doi.org/10.17323/1813-8691-2022-26-4-598-622>
- Makeeva N.M., Stankevich I.P., Lyubaykin N.S. (2024) Nowcasting the Russian Economy Macroeconomic Indicators under Uncertainty: Does Taking into Account the News Sentiment Help. *Voprosy Ekonomiki*, 3, pp. 120–142. (In Russ.) <https://doi.org/10.32609/0042-8736-2024-3-120-142>
- Makeeva N. (2025) The Impact of the Official Statistics Revision on the Accuracy of the Russian Macroeconomic Indicators Nowcasting Models. *Applied Econometrics*, 79, pp. 27–49. (In Russ.) <https://doi.org/10.22394/1993-7601-2025-79-27-49>
- Mitchell J., Poon A., Mazzi G.L. (2022) Nowcasting Euro Area GDP Growth Using Bayesian Quantile Regression. *Essays in Honor of M. Hashem Pesaran: Prediction and Macro Modeling* (eds. A. Chudik et al.). Emerald Group Publishing Limited. Ch. 3. <https://doi.org/10.1108/S0731-90532021000043A004>
- Polbin A., Shumilov A. (2025) Nowcasting and Forecasting Russian GDP and its Components Using Quantile Models. *Applied Econometrics*, 79, pp. 5–26. (In Russ.) <https://doi.org/10.22394/1993-7601-2025-79-5-26>
- Rybak K.S. (2023) Evaluating the Role of Global Factors in GDP Nowcasting. *Russian Economic Development*, 3, 12, pp. 18–22. (In Russ.)
- Stankevich I. (2023) Application of Markov-Switching MIDAS Models to Nowcasting of GDP and its Components. *Applied Econometrics*, 2, 70, pp. 122–143. (In Russ.) <https://doi.org/10.22394/1993-7601-2023-70-122-143>
- Taylor J.W. (2000) A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns. *Journal of Forecasting*, 19, 4, pp. 299–311. [https://doi.org/10.1002/1099-131X\(200007\)19:4<299::AID-FOR775>3.0.CO;2-V](https://doi.org/10.1002/1099-131X(200007)19:4<299::AID-FOR775>3.0.CO;2-V)
- Zubarev A.V., Rybak K.S. (2021) GDP Nowcasting: Dynamic Factor Model vs. Official Forecasts. *Russian Economic Development*, 28, 12, pp. 34–40. (In Russ.)
- Zubarev A., Lomonosov D., Rybak K. (2022) Estimation of the Impact of Global Shocks on the Russian Economy and GDP Nowcasting Using a Factor Model. *Russian Journal of Money and Finance*, 81, 2, pp. 49–78.