

Вестник Самарского государственного экономического университета. 2025. № 7 (249). С. 115–130.
Vestnik of Samara State University of Economics. 2025. No. 7 (249). Pp. 115–130.

ФИНАНСЫ, ДЕНЕЖНОЕ ОБРАЩЕНИЕ И КРЕДИТ

Научная статья
УДК 330.42

Прогнозирование уровня инфляции на основе больших данных в условиях реализации политики импортозамещения

Юрий Евгеньевич Александрович¹, Ирина Александровна Еремина²

^{1,2} Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург,
Россия

¹ irenalks.orags@mail.ru

² dokukina.orags@mail.ru

Аннотация. В статье рассматриваются методы прогнозирования уровня инфляции с использованием анализа больших данных в контексте реализации политики импортозамещения. Актуальность исследования определяется необходимостью адаптации экономической политики к современным вызовам, связанным с глобальными изменениями и внутренними экономическими процессами. Авторами научно обосновано, что применение методов анализа больших данных позволяет повысить точность прогнозов и улучшить управленческие решения, что в свою очередь способствует устойчивому развитию экономики. Научная новизна заключается в адаптации методов прогнозирования к специфике экономики, ориентированной на импортозамещение, это включает учет изменений в структуре производства, логистических цепочек и потребительских предпочтений, что ранее не рассматривалось в рамках классических моделей прогнозирования инфляции. Результаты исследования могут стать основой для разработки более точных и адаптивных инструментов управления инфляционными процессами в условиях экономической трансформации.

Ключевые слова: инфляция, большие данные, политика импортозамещения, FAVAR-модели, DMS- и DMA-модели, методы машинного обучения, алгоритм случайного леса, алгоритм градиентного бустинга

Основные положения:

♦ представлено теоретическое обоснование необходимости исследования прогнозирования уровня инфляции на основе больших данных в условиях реализации политики импортозамещения. Обоснована целесообразность следующих методов оценивания: FAVAR-модели, DMS- и DMA-модели, методов машинного обучения (алгоритм случайного леса, алгоритм градиентного бустинга);

♦ представлено прогнозирование инфляции с помощью различных методов оценки с последующим определением качества прогноза;

♦ проведен сравнительный анализ моделей между собой по качеству относительно эталонной модели линейной регрессии.

Для цитирования: Александрович Ю.Е., Еремина И.А. Прогнозирование уровня инфляции на основе больших данных в условиях реализации политики импортозамещения // Вестник Самарского государственного экономического университета. 2025. № 7 (249). С. 115–130.

Original article

Forecasting the inflation rate based on big data in the context of implementing import substitution policies

Yuri E. Alexandrovich¹, Irina A. Eremina²

^{1,2} Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹ irenalks.orags@mail.ru

² dokukina.orags@mail.ru

Abstract. This article considers inflation forecasting methods using big data analysis in the context of import substitution policy implementation. The relevance of the study is determined by the need to adapt economic policy to modern challenges associated with global changes and internal economic processes. The authors scientifically substantiate that the use of big data analysis methods can increase the accuracy of forecasts and improve management decisions, which in turn contributes to sustainable economic development. Scientific novelty lies in the adaptation of forecasting methods to the specifics of an economy focused on import substitution, this includes taking into account changes in the structure of production, supply chains and consumer preferences, which has not previously been considered within the framework of classical inflation forecasting models. The results of the study can form a basis for developing more accurate and adaptive tools for managing inflation processes in the context of economic transformation.

Keywords: inflation, big data, import substitution policy, FAVAR models, DMS and DMA models, machine learning methods, random forest algorithm, gradient boosting algorithm

Highlights:

- ♦ the theoretical justification for the need to study inflation forecasting based on big data in the context of import substitution policy implementation is presented; the feasibility of the following assessment methods is substantiated: FAVAR models, DMS and DMA models, machine learning methods (random forest algorithm, gradient boosting algorithm);
- ♦ inflation forecasting using various assessment methods with subsequent determination of forecast quality is presented;
- ♦ a comparative analysis of the models among themselves in terms of quality relative to the reference linear regression model is carried out.

For citation: Alexandrovich Yu.E., Eremina I.A. Forecasting the inflation rate based on big data in the context of implementing import substitution policies // Vestnik of Samara State University of Economics. 2025. No. 7 (249). Pp. 115–130. (In Russ.).

Введение

В современной экономике инфляция остается одним из ключевых макроэкономических показателей, оказывающих значительное влияние на финансовую стабильность, уровень жизни населения и инвестиционную привлекательность страны. В условиях глобальной нестабильности и реализации политики импортозамещения, направленной на снижение зависимости от иностранных товаров и технологий, прогнозирование уровня инфляции приобретает особую актуальность. Традиционные ме-

тоды анализа, основанные на ограниченных наборах данных, зачастую не способны учесть всю сложность и многогранность факторов, влияющих на инфляционные процессы.

В настоящее время прогнозирование инфляции играет ключевую роль в условиях реализации политики импортозамещения, и несмотря на то что существует множество макроэкономических моделей, это остается достаточно сложным вопросом. Самые популярные подходы к этому основаны на модификациях кривой Филлипса и рекурсивных методах. Од-

нако и у них есть свои недостатки: во-первых, оцененные коэффициенты могут меняться во времени; во-вторых, количество предикторов может быть большим, поэтому приходится оценивать огромное количество моделей, что, на самом деле, имеет большую вычислительную сложность; в-третьих, модель, на основе которой строится прогноз, может также изменяться во времени.

Цель данного исследования – рассмотреть методы прогнозирования уровня инфляции на основе больших данных, а также оценить их эффективность в условиях реализации политики импортозамещения.

Задачи исследования: теоретический обзор по прогнозированию инфляции и описание основных методов машинного обучения для прогнозирования; сравнение и критический анализ эмпирических подходов к прогнозированию на основе больших данных.

В своем исследовании А.В. Бабкин и Е.В. Шкарупета изучают закономерность между качеством и объемом используемых данных, авторами строится несколько экономических и статистических моделей, экономические модели основаны на предположениях теории, они построены на небольшом наборе факторов и стремятся уловить глобальные взаимосвязи между ключевыми факторами. Статистические модели позволяют учесть информацию из большого объема данных, т.е. используют всю доступную информацию, чтобы как можно точнее описать действительность. Показатели, используемые для получения прогноза инфляции: обменный курс, номинальная и реальная процентная ставка, предложение денег, ВВП (валовой внутренний продукт), административная инфляция, ВВП (валовой национальный продукт) [1].

Г.Т. Андыбаева, А.К. Абитова в своей работе стоили прогнозы по модели FAVAR (factor-augmented vector autoregressive model) для краткосрочного, среднесрочного и долгосрочного горизонта планирования и сравнивали их с эталонными прогнозами по AR-модели. Прогнозы строились по одним регрессорам путем добавления к ним новых, т.е. постепенным расширением информационного множества. А также оценивались модели с разным количеством лагов и используемых факторов [2]. В

целом, авторам удалось показать, что модели FAVAR для прогнозирования уровня инфляции лучше по сравнению с эталонными AR-моделями, более того, качество FAVAR-моделей улучшается с увеличением горизонта прогнозирования. Так, на долгосрочном горизонте почти для всех моделей удалось существенно улучшить качество прогноза.

В.Д. Андрианов в своей работе прогнозирует уровень инфляции на основе моделей динамического усреднения (DMA – dynamic model averaging), он рассматривает ежеквартальные данные по 14 регрессорам и двум зависимым переменным (дефлятор ВВП, дефлятор цен на личные потребительские расходы) [3].

Рассмотрим эмпирические результаты, которые получили Л.А. Васин, В.В. Ростовцев при оценке моделей DMS и DMA [4]. Авторы отмечают, что на коротких временных горизонтах используется меньшее количество объясняющих переменных, чем на длинных.

Используемые О.В. Заборовской, Л.А. Аксеновой модели DMA и DMS имеют два экзогенных параметра, которые отвечают за «скорость забывания». Затем авторы оценивают несколько имеющихся моделей с разными значениями параметров. Выбирают наилучшую модель по критериям: среднеквадратической ошибки, абсолютной ошибки. Таким образом, лучшие прогнозы показывают модели DMA и DMS, потом они предлагают перебрать несколько значений и по сетке (Grid search) для поиска оптимального значения на каждом временном горизонте [5].

Для применения моделей динамического усреднения для российской экономики рассмотрим работу А.А. Зайцева, Н.Д. Дмитриева, Е.А. Михель. Авторы прогнозируют инфляцию на основе российских данных с января 2007 г. по сентябрь 2018 г. В качестве бенчмарка (эталонной модели) выбран класс байесовских моделей, с которыми и сравнивается качество прогнозов для DMA и DMS. Прогнозирование осуществлялось на 1–6 месяцев вперед. Интересным наблюдением стало то, что самые информативные регрессоры менялись в зависимости от горизонта планирования [6]. В работе Р.В. Колесова, А.Ю. Тарасова, Г.Е. Козлова применяются ансамблевые методы машин-

ного обучения для прогнозирования инфляции в российской экономике [7]. Поскольку лаги инфляции не входят в объясняемые переменные, то такие модели показывают высокую устойчивость к шокам. Отметим, что случайный лес более устойчив к шокам, чем градиентный бустинг. А.А. Зайцевым Н.Д. Дмитриевым, Д.Г. Родионовым были получены схожие результаты, что говорит об устойчивости и большой предсказательной силе ансамблевых методов [8]. Модели с регуляризацией Lasso и Ridge показали менее точные результаты на всех горизонтах прогнозирования относительно бенчмарка. Замечено, что число регрессоров также сильно падает с увеличением горизонта прогнозирования. Данная нестабильность модели может говорить о том, что нет подходящего набора объясняющих переменных. Таким образом, для российской экономики была показана актуальность использования ансамблевых методов и моделей динамического усреднения.

В отличие от традиционных методов, которые опираются на ограниченные наборы макроэкономических показателей, предлагаемый авторский подход позволяет учитывать широкий спектр факторов, включая изменения в структуре потребительского спроса, динамику цен на товары и услуги, а также данные о внешнеэкономической активности и производственных процессах.

Методы

В ходе исследования применялись следующие методы оценивания: FAVAR-модели, DMS и DMA-модели, методы машинного обучения (алгоритм случайного леса, алгоритм градиентного бустинга).

Модель FAVAR сочетает элементы векторной авторегрессии (VAR) с факторным анализом, она дает возможность учитывать большое количество экономических индикаторов, выделяя из них основные факторы, влияющие на целевой показатель (в данном случае – уровень инфляции). FAVAR-модели используются для учета взаимосвязей между множеством экономических переменных, что особенно важно в условиях сложной экономической среды, как, например, в условиях импортозамещения.

Dynamic Model Selection (DMS) – это подход, который позволяет автоматически выбирать наиболее подходящую модель из множества возможных на каждом этапе прогнозирования [9]. В контексте прогнозирования инфляции DMS может учитывать изменения в структуре данных, вызванные политикой импортозамещения, такие как сдвиги в потребительских предпочтениях или изменения в цепочках поставок. Например, если в экономике происходит резкий переход от импортных товаров к отечественным, DMS может оперативно переключиться на модель, которая лучше учитывает новые данные о ценах и спросе на локальную продукцию.

Dynamic Model Averaging (DMA) – это расширение подхода DMS, которое вместо выбора одной модели использует взвешенное среднее нескольких моделей. Веса моделей динамически обновляются на основе их прошлой точности, что позволяет учитывать неопределенность и изменчивость экономической среды [10]. В условиях импортозамещения DMA может быть особенно полезен, так как позволяет комбинировать прогнозы из моделей, учитывающих различные аспекты экономической трансформации, такие как изменения в производственных мощностях, тарифах на импорт или потребительской инфляции.

Прогнозирование уровня инфляции с использованием методов машинного обучения на основе больших данных включает несколько ключевых этапов: сбор и подготовку данных о макроэкономических показателях, выбор и применение различных моделей, таких как линейная регрессия, деревья решений, случайные леса, градиентный бустинг и нейронные сети, а также оценку их производительности с помощью кросс-валидации и метрик, таких как RMSE и MAE [11]. Важно также учитывать специфику политики импортозамещения, адаптируя модели к изменениям в спросе на внутренние товары и воздействию внешних шоков.

Алгоритм случайного леса (Random Forest, RF) является одним из наиболее эффективных методов машинного обучения для задач регрессии и классификации. Его применение для прогнозирования уровня инфляции в условиях реализации политики импортозамещения мо-

жет быть особенно полезным благодаря способности алгоритма работать с большими объемами данных, учитывать нелинейные зависимости и обрабатывать множественные факторы, влияющие на инфляцию.

Алгоритм градиентного бустинга (Gradient Boosting, GB) является одним из самых мощных методов машинного обучения для задач регрессии и классификации. Его применение для прогнозирования уровня инфляции в условиях реализации политики импортозамещения позволяет учитывать сложные нелинейные зависимости и динамические изменения в экономике, вызванные переходом на отечественные товары и услуги.

Результаты

Показатели, используемые в исследовании для прогнозирования уровня инфляции в условиях реализации политики импортозамещения, представлены в табл. 1.

Часть регрессоров была скорректирована на сезонность. Каждый ряд был проверен на стационарность расширенным тестом Дики-Фуллера с наличием константы и линейного тренда. Тест проводился только на обучающей выборке (до 2018 г. включительно), и было отмечено, что при расширении временного ряда (т.е. с учетом 2019 г.) тест на 5% уровне значимости чаще начал не отклонять нулевую гипотезу о наличии единичного корня. Все ряды с наличием единичного корня были приведены к стационарному виду с помощью перехода к разностям.

Также отметим, что инфляция имеет структуру временного ряда, т.е. будущие значения инфляции сильно коррелированы с предыдущими. Поэтому большинство экономистов считают, что процесс порождения данных об инфляции имеет адаптивный характер, а не рациональный [12]. В связи с чем в данном исследовании в модель включены лаги инфляции вплоть до второго порядка. Для сопоставления моделей между собой будем обучать их на выборке до 2018 г. включительно и смотреть на качество прогноза. Это позволяет честно сравнить модели между собой по метрикам качества прогноза: корню из среднеквадратичной ошибки прогноза, средней абсолютной ошибке прогноза.

Модели случайного леса и градиентного бустинга были построены на основе всех имеющихся данных. Поскольку инфляция имеет адаптивный характер, то включался первый и второй лаг инфляции всех горизонтов.

Например, при прогнозировании месячной инфляции учитываем не только лаги месячной инфляции, но и лаги 3-, 6-, 9- и 12-месячной инфляции, таким образом, учитывая временную динамику ряда.

Результаты оценивания случайного леса приведены на рис. 1.

Отметим, что на всех графиках качество прогноза в среднем лучше на выборке с 2006 г., это может быть следствием отсутствия влияния объема услуг населению на уровень инфляции и наличие большего количества наблюдений. Что касается выбора дата сета, то для сырых данных качество почти всегда (кроме горизонта в 1 и 12 месяцев) выше, чем для остационаренных с корректировкой сезонности. Для учета специфики импортозамещения необходимо проверить, как изменилась зависимость инфляции от ключевых факторов после начала политики импортозамещения, а также учитывать, что эффекты импортозамещения могут проявляться с задержкой (например, через 6–12 месяцев).

Построим также значимость регрессоров для прогнозов, основанных на дата сете untransformed для данных с 2006 г. (рис. 2).

С изменением горизонта прогнозирования меняются и важные регрессоры, сделаем несколько замечаний. Во-первых, лаговые значения нецелевых инфляций оказывают сильное влияние на прогноз, часто даже большее, чем лаги целевого. Во-вторых, в краткосрочном горизонте ($h = 1, 3$) чаще используются номинальные показатели. В-третьих, лаги инфляции больше имеют влияние при $h = 6, 9$, монетарные и валютные показатели при $h = 12$, а ключевая ставка, миакр и номинальные показатели при $h = 1, 3$. Также почти для всех временных горизонтов важны лаги долгосрочной ($h = 9, 12$) инфляции. Проведем аналогичный анализ и для следующей модели.

Прогнозирование инфляции с помощью градиентного бустинга представлено на рис. 3.

Во-первых, видно, что с увеличением горизонта прогнозирования сложнее бороться с

Таблица 1

Показатели, используемые в исследовании*

Показатели	Расшифровка	Показатели	Расшифровка
effective_dollar_rate	Индекс номинального курса рубля к доллару США, % прироста к предыдущему периоду	miarc_1	Ставка межбанковского кредитного рынка на 1 день
effective_euro_rate	Индекс номинального курса рубля к евро, % прироста к предыдущему периоду	miarc_2_7	Ставка межбанковского кредитного рынка от 2 до 7 дней
effective_rate	Индекс номинального эффективного курса рубля к иностранным валютам, % прироста к предыдущему периоду	miarc_8_30	Ставка межбанковского кредитного рынка от 8 до 30 дней
real_effective_dollar_rate	Индекс реального курса рубля к доллару США, % прироста к предыдущему периоду	miarc_31_90	Ставка межбанковского кредитного рынка от 31 до 90 дней
real_effective_euro_rate	Индекс реального курса рубля к евро, % прироста к предыдущему периоду	nominal_wage	Номинальная заработная плата
real_effective_rate	Индекс реального эффективного курса рубля к иностранным валютам, % прироста к предыдущему периоду	real_wage	Реальная заработная плата
dollar_rate	Средний номинальный курс доллара США к рублю за период	industrial_production_index	Индекс промышленного производства
euro_rate	Средний номинальный курс евро к рублю за период	real_effective_rate	Реальный эффективный курс рубля
housing_services	Бытовые услуги населению	foreign_exchange_reserves	Валютные резервы ЦБ
household_services	Жилищные услуги населению	real_m0	Реальное предложение денег (M0)
utilities_services	Коммунальные услуги населению	real_m2	Реальное предложение денег (M2)
medical_services	Медицинские услуги населению	real_agricultural_index	Индекс реального объема сельскохозяйственного производства
educational_services	Образовательные услуги населению	real_construction_index	Реальный объем работ, выполненных по виду деятельности «Строительство» в текущих ценах
transport_services	Транспортные услуги населению	construction_index	Объем работ, выполненных по виду деятельности «Строительство» в текущих ценах
oil_price	Цена фьючерсов на нефть	real_retail_turnover_index	Индекс реального оборота розничной торговли
nickel_price	Цена фьючерсов на никель	retail_turnover_index	Индекс оборота розничной торговли
alum_price	Цена фьючерсов на алюминий	unemployment	Уровень безработицы
wheat_price	Цена фьючерсов на пшеницу	inflation	Уровень инфляции
m2	Предложение денег (M2)	retail_turnover	Розничный товароборот
m0	Предложение денег (M0)	cash	Наличные деньги в обращении
banks_reserves	Резервы кредитных организаций в Банке России	import	Импорт
export	Экспорт	net_export	Сальдо торгового баланса
key_rate	Ключевая ставка ЦБ	international_reserves	Международные резервы Российской Федерации

* Показатели отобраны автором согласно цели исследования.




Рис. 1. Прогноз инфляции для модели случайного леса

переобучением, кривая прогноза на обучении все точнее предсказывает значение инфляции. Во-вторых, как и для случайного леса качество предсказания лучше на дата сете с 2006 г. В-третьих, прогноз на сырых данных практически всегда дает предсказание лучше по средней абсолютной ошибке и по средне-квадратической ошибке. Также с ростом горизонта прогнозирования падает качество прогноза (за исключением горизонта в 9 месяцев), однако это скорее недочет оценивания, который может быть связан с переобучением

и неоптимальным подбором параметров в силу ограниченности ресурсов. На месячном горизонте прогнозирования модели не удалось уловить все пики и падения, на других горизонтах они улавливаются хотя бы с небольшим лагом. Месячная инфляция труднее всего для прогнозирования, поскольку имеет большую волатильность, в то время как годовая тагетирована Центральным банком и имеет больший период, поэтому с ростом горизонта кривая становится глаже. Однако со снижением волатильности прогнозировать инфляцию не




Рис. 2. Ключевые показатели для модели случайного леса




Рис. 3. Прогноз инфляции для модели градиентного бустинга

становится проще, это связано с изменением важных факторов. Также посмотрим на важность регрессоров при прогнозировании на данных с 2006 г. (рис. 4). Отметим, что для сырых данных первый фактор оказывает заметно большее влияние, чем последующие, начиная с $h = 3$. Более интересным является факт того, что лаги месячной инфляции оказывают большее влияние на долгосрочную ($h = 9, 12$) инфляцию для сырых данных, причем ка-

чество прогноза сопоставимо со случайным лесом, в котором такой тенденции не наблюдалось. Для успешного прогнозирования и реализации инфляции в условиях реализации политики импортозамещения важно учитывать как макроэкономические, так и отраслевые показатели. Модель градиентного бустинга позволяет эффективно анализировать сложные зависимости и выявлять ключевые факторы, влияющие на успех импортозамещения.




Рис. 4. Ключевые показатели для модели градиентного бустинга




Рис. 5. Прогноз инфляции для DMS

Подбор и оценивание модели DMS никак не отличается от DMA. Результаты прогнозирования можно посмотреть на рис. 5.

Заметим, что для всех построенных моделей качество прогноза разнонаправлено меняется в зависимости от горизонта прогнозирования и года. Также качество годового прогноза выше, чем для ансамблевых методов и примерно сопоставимо с моделью DMA. Однако качество данных моделей можно улучшить, попробовав применить к ним другие методы шкалирования и обработки (процедуры

корректировки сезонности и остационирования) данных.

Обсуждение

Теперь сравним модели между собой по качеству относительно эталонной модели линейной регрессии, построенной на основе важных 12 факторов для 2006 г., потому что на данных с 2010 г. тест Дики-Фуллера чаще не отклоняет гипотезу о наличии единичного корня, что приводит к частым переходам в разности, там где этого делать не нужно, и сильно

Таблица 2

Линейная регрессия: метрики качества

h	RMSE	MAE	R_{adj}^2
1	0.26	0.22	0.761
3	0.43	0.39	0.891
6	0.50	0.41	0.969
9	0.43	0.35	0.987
12	0.32	0.36	0.995




Рис. 6. Прогноз инфляции по линейной регрессии

ухудшает качество прогноза для линейной регрессии. Эта модель показала качество лучше, чем просто модель ARIMA, поскольку учитывает лаги инфляции других горизонтов, что говорит об устойчивости прогноза. Однако име-

ется и ряд недостатков, линейное включение 9-месячной инфляции может быть не лучшим решением, поскольку инфляция мультипликативна, также при построении модели можем столкнуться с проблемой зависимости регрес-

соров друг от друга: градиентный бустинг в отличие от линейной регрессии инвариантен в отношении мультиколлинеарности переменных, поэтому такой выбор регрессоров может привести к неустойчивости оценок. Чтобы избежать этих проблем решили оставить только первый лаг прогнозируемого горизонта и значимые на 5%-ном уровне переменные. На всех горизонтах прогнозирования видим достаточно высокую точность прогнозирования (табл. 2), при $h = 12$ ошибки прогноза меньше при других h , что можно объяснить: во-первых, инфляция на долгом горизонте менее волатильная и, значит, легче предсказуема; во-вторых, темп годовой инфляции важен для проведения монетарной политики, поэтому ЦБ стремится сделать его более стабильным. Прогноз инфляции по линейной регрессии представлен на рис. 6.

Теперь, используя данные табл. 2, построим относительное качество прогнозов, для этого сформируем табл. 3, 4, в которых светло-серым цветом выделены модели, в которых качество совпало с эталонным, и темно-серым, в которых качество превзошло эталонное. Для проверки гипотезы использовался критерий Диболда-Мариано на основе средне-квадратической ошибки. Ансамблевые мо-

дели, включая градиентный бустинг и случайный лес, продемонстрировали сопоставимое или более высокое качество прогнозов на сырых данных по сравнению с эталонной моделью. В частности, модель градиентного бустинга превзошла эталонную модель на данных, начиная с 2006 г., на горизонте прогноза в 9 месяцев. Это указывает на ее более высокую предсказательную силу по сравнению с моделью случайного леса. В среднем качество прогнозов на сырых данных оказалось выше, что объясняется нечувствительностью ансамблевых методов к таким этапам предобработки, как стационаризация, удаление сезонности и другие преобразования данных.

Для некоторых горизонтов прогноза качество ансамблевых моделей превышает показатели эталонной модели, однако эта разница не является статистически значимой на уровне значимости 5%. Это связано с тем, что ансамблевые методы, такие как градиентный бустинг и случайный лес, способны эффективно моделировать сложные нелинейные зависимости и взаимодействия между переменными, что делает их менее зависимыми от предварительной обработки данных. Градиентный бустинг, в частности, часто показывает лучшее качество прогнозов благодаря после-

Таблица 3

Модели динамического усреднения: относительные метрики качества

year	h	dataset	$RMSE_{dma}$	MAE_{dma}	$RMSE_{dms}$	MAE_{dms}
2006	1	pca	1.0025	0.9594	0.9788	0.9940
2006	1	standart_key	1.9414	2.0114	1.9429	2.0136
2006	3	pca	1.3908	1.1795	1.2352	1.0315
2006	3	standart_key	1.8874	1.7850	1.5860	1.3883
2006	6	pca	1.8870	1.8815	1.9486	1.9105
2006	6	standart_key	2.6196	2.8626	2.7017	2.7843
2006	9	pca	1.8301	2.0561	2.2826	2.5871
2006	9	standart_key	1.7327	1.8041	1.8479	2.1094
2006	12	pca	1.6204	1.6089	1.5775	1.6407
2006	12	standart_key	0.4783	0.4287	0.5502	0.5208
2010	1	pca	1.2116	1.0579	1.8452	1.7674
2010	1	standart_key	1.0363	0.9085	1.2215	1.0395
2010	3	pca	1.6745	1.4627	1.8238	1.6559
2010	3	standart_key	2.4426	2.4521	2.4604	2.4763
2010	6	pca	2.1090	2.3204	2.0113	2.1247
2010	6	standart_key	1.9285	1.9138	2.0921	2.3277
2010	9	pca	2.1083	2.2993	2.2219	2.3592
2010	9	standart_key	2.1286	2.5613	2.0225	2.3974
2010	12	pca	2.2963	2.1961	2.3003	2.2130
2010	12	standart_key	0.5839	0.5822	0.5577	0.5625

Таблица 4

Ансамблевые модели: относительные метрики качества

year	h	dataset	$RMSE_{rf}$	MAE_{rf}	$RMSE_{gb}$	MAE_{gb}
2006	1	transformed	1.0386	1.1048	1.1571	1.2047
2006	1	untransformed	0.8764	0.9176	0.8722	0.8703
2006	3	transformed	1.3554	1.3163	1.4688	1.3916
2006	3	untransformed	0.8059	0.7871	0.5305	0.5111
2006	6	transformed	2.2640	2.3248	2.1093	2.3356
2006	6	untransformed	0.9516	1.0023	1.1464	1.2504
2006	9	transformed	2.0513	1.9869	2.3449	2.6471
2006	9	untransformed	1.4708	1.7322	0.9861	1.1075
2006	12	transformed	0.9736	0.9516	0.9763	1.0289
2006	12	untransformed	1.7799	1.9778	1.8569	1.9657
2010	1	transformed	0.7937	0.7851	1.1079	1.0744
2010	1	untransformed	0.9594	1.0236	0.9708	0.8877
2010	3	transformed	1.4145	1.2860	1.6225	1.4617
2010	3	untransformed	0.7629	0.7245	0.7775	0.7357
2010	6	transformed	2.1337	2.1947	1.4953	1.5845
2010	6	untransformed	1.1585	1.3128	1.3238	1.4606
2010	9	transformed	1.6855	1.7327	1.9133	2.1205
2010	9	untransformed	1.5564	1.8677	1.2484	1.3115
2010	12	transformed	1.0861	1.0727	1.1171	1.0750
2010	12	untransformed	1.7305	1.8227	1.3280	1.3374

довательной оптимизации ошибок и использованию ансамбля слабых моделей (деревьев решений). Однако сделаем некоторые замечания относительно таких ячеек, поскольку тесту на 12 наблюдениях могло не хватить мощности для отклонения гипотезы. На горизонте $h = 1, 3, 12$ месяцев ансамблевым методам удалось улучшить качество эталонной модели, как правило, на сырых данных с 2006 г. Для этих моделей качество случайного леса, как правило, сопоставимо качеству градиентного бустинга.

Анализ для моделей динамического усреднения показал, что для обоих годов и дата сетов качество на месячном горизонте совпало с эталонным, что верно и для 3-месячного горизонта для модели градиентного бустинга для дата сета рса с 2006 г. Улучшить прогноз по сравнению с бенчмарком удалось обоим моделям на standart_key дата сете. При горизонте в 6 и 9 месяцев не удалось достичь качества сопоставимого или выше для моделей динамического усреднения.

Прогнозы, построенные на ансамблевых методах на коротких горизонтах, превосходят прогнозы динамических моделей. Это может быть связано с неправильным выбором обработки данных: процессом остационирования,

очистки от сезонности или скалирования. Однако на годовом горизонте прогноз DMS- и DMA-моделей оказался самым точным, в 2 раза лучше других моделей. В целом, результаты прогнозирования показали целесообразность использования и деревьев, и моделей динамического усреднения для прогнозирования инфляции в условиях реализации политики импортозамещения. Результаты демонстрируют, что ансамблевые методы, особенно градиентный бустинг, являются мощным инструментом для прогнозирования на сырых данных. Однако важно учитывать, что на некоторых горизонтах разница в качестве прогнозов может быть незначимой, что требует дополнительного анализа и, возможно, комбинирования моделей для достижения наилучших результатов.

Заключение

В данном исследовании был продемонстрирован значительный потенциал ансамблевых методов и моделей динамического усреднения (Dynamic Model Averaging, DMA) в задаче прогнозирования уровня инфляции в условиях политики импортозамещения. Использование этих подходов позволило учесть сложные взаимосвязи между множеством

факторов, влияющих на инфляцию, и адаптироваться к динамическим изменениям в экономике в условиях внешнеэкономических санкций, особенно в условиях реализации политики импортозамещения. В ходе исследования были выявлены следующие ключевые факторы, оказывающие значительное влияние на уровень инфляции: международные резервы (их объем и динамика влияют на стабильность национальной валюты и способность Центрального банка контролировать инфляцию), курсы валют (номинальный, реальный и эффективный курсы валют играют важную роль в формировании инфляционных ожиданий, особенно в условиях изменения структуры импорта и экспорта), цены на сырьевые товары (такие как цена на пшеницу и алюминий, оказывают прямое влияние на стоимость товаров и услуг), ставка MIACR (Moscow Interbank Actual Credit Rate, отражает стоимость заимствований на межбанковском рынке и влияет на кредитную активность), наличные деньги в обращении (их объем связан с потребительским спросом и ликвидностью в экономике). В ходе исследования удалось построить модели с высоким качеством прогнозирования, которые превзошли

бенчмарк на следующих горизонтах: месячный горизонт, 3-месячный горизонт (на среднесрочном горизонте ансамблевые методы и DMA продемонстрировали устойчивость и способность учитывать изменения в экономической динамике), годовой горизонт (на долгосрочном горизонте модели также показали высокую точность, что подтверждает их пригодность для стратегического планирования). Ансамблевые методы (например, градиентный бустинг и случайный лес) позволили объединить сильные стороны различных моделей и повысить точность прогнозов. Динамическое усреднение моделей (DMA) обеспечило адаптивность к изменениям в экономической среде, что особенно важно в условиях импортозамещения. Несмотря на успешные результаты, стоит отметить, что модели показали высокую точность только на месячном, 3-месячном и годовом горизонтах.

Таким образом, применение ансамблевых методов и моделей динамического усреднения открывает новые возможности для повышения точности прогнозирования инфляции в условиях реализации политики импортозамещения и других экономических трансформаций.

Список источников

1. Бабкин А.В., Шкарупета Е.В. Козволюционно-конвергентный потенциал ESG 5.0 как драйвер промышленного роста экономики России в многополярном мире // Экономика и управление. 2024. Т. 30, № 8. С. 953–971.
2. Андыбаева Г.Т., Абитова А.К. Методы корректировки показателей финансовой отчетности в условиях инфляции // Евразийское Научное Объединение. 2020. № 10-4 (68). С. 265–268.
3. Андрианов В.Д. Функциональная экономическая система, регулирующая уровень инфляции // Маркетинг. 2010. № 4 (113). С. 3–19.
4. Васин Л.А., Ростовцев В.В. Прогнозирование уровня инфляции в условиях нестабильности внешней среды // Финансы и кредит. 2010. № 43 (427). С. 25–28.
5. Заборовская О.В., Аксенова Л.А. Государственная политика поддержки благотворительной деятельности как фактор устойчивого социально-экономического развития страны и регионов // Вестник Академии знаний. 2024. № 2 (61). С. 623–627.
6. Зайцев А.А., Дмитриев Н.Д., Михель Е.А. Структурно-аналитическая модель ресурсного потенциала в системе экономических отношений // Международный сельскохозяйственный журнал. 2024. № 1 (397). С. 32–36.
7. Колесов Р.В., Тарасова А.Ю., Козлов Г.Е. Прогнозирование уровня инфляции при формировании региональных и муниципальных бюджетов // Экономика. Налоги. Право. 2019. Т. 12, № 4. С. 102–110.
8. Зайцев А.А., Дмитриев Н.Д., Родионов Д.Г. Инструментарий диагностики продовольственной безопасности территории как составляющей ее ресурсного потенциала // Международный сельскохозяйственный журнал. 2024. № 2 (398). С. 144–148.
9. Конников Е.А. Моделирование свойств предприятия как субъекта информационной среды в контексте развития региональных пространственно-локализованных подсистем // Экономика Северо-Запада: проблемы и перспективы развития. 2024. № 3 (78). С. 151–157.

10. Соколинская И.М. Синтез симплекс-метода и метода линейной коррекции в задачах линейной оптимизации с неформализованными ограничениями // Вычислительные методы и программирование. 2005. Т. 6, № 1. С. 226–238.
11. Родионов Д.Г. Импортозамещение как стратегия экономического развития // Экономические науки. 2020. № 5. С. 15–22.
12. Чистяков И.Д. Прогнозирование уровня инфляции в России на основе эконометрического моделирования // Аллея науки. 2018. Т. 4, № 4 (20). С. 213–220.

References

1. Babkin A.V., Shkarupeta E.V. Coevolutionary and convergent potential of ESG 5.0 as a driver of industrial growth of the Russian economy in a multipolar world // Economics and Management. 2024. Vol. 30, No. 8. Pp. 953–971.
2. Andybaeva G.T., Abitova A.K. Methods for adjusting financial statement indicators in the context of inflation // Eurasian Scientific Association. 2020. No. 10-4 (68). Pp. 265–268.
3. Andrianov V.D. Functional economic system regulating the level of inflation // Marketing. 2010. No. 4 (113). Pp. 3–19.
4. Vasin L.A., Rostovtsev V.V. Forecasting the inflation rate in the context of an unstable external environment // Finance and Credit. 2010. No. 43 (427). Pp. 25–28.
5. Zaborovskaya O.V., Aksenova L.A. State policy of supporting charitable activities as a factor in sustainable socio-economic development of the country and regions // Bulletin of the Academy of Knowledge. 2024. No. 2 (61). Pp. 623–627.
6. Zaitsev A.A., Dmitriev N.D., Mikhel E.A. Structural and analytical model of resource potential in the system of economic relations // International Agricultural Journal. 2024. No. 1 (397). Pp. 32–36.
7. Kolesov R.V., Tarasova A.Yu., Kozlov G.E. Forecasting the inflation rate in the formation of regional and municipal budgets // Economy. Taxes. Law. 2019. Vol. 12, No. 4. Pp. 102–110.
8. Zaitsev A.A., Dmitriev N.D., Rodionov D.G. Tools for diagnosing food security of a territory as a component of its resource potential // International Agricultural Journal. 2024. No. 2 (398). Pp. 144–148.
9. Konnikov E.A. Modeling the properties of an enterprise as a subject of the information environment in the context of the development of regional spatially localized subsystems // Economy of the North-West: problems and development prospects. 2024. No. 3 (78). Pp. 151–157.
10. Sokolinskaya I.M. Synthesis of the simplex method and the linear correction method in linear optimization problems with non-formalized constraints // Computational methods and programming. 2005. Vol. 6, No. 1. Pp. 226–238.
11. Rodionov D.G. Import substitution as a strategy for economic development // Economic sciences. 2020. No. 5. Pp. 15–22.
12. Chistyakov I.D. Forecasting the inflation rate in Russia based on econometric modeling // Alley of Science. 2018. Vol. 4, No. 4 (20). Pp. 213–220.

Информация об авторах

Ю.Е. Александрович – соискатель Высшей инженерно-экономической школы Санкт-Петербургского политехнического университета Петра Великого;

И.А. Еремина – доктор экономических наук, доцент, профессор Высшей инженерно-экономической школы Санкт-Петербургского политехнического университета Петра Великого.

Information about the authors

Yu.E. Alexandrovich – applicant of the Higher School of Engineering and Economics of Peter the Great St. Petersburg Polytechnic University;

I.A. Eremina – Doctor of Economics, Associate Professor, Professor of the Higher School of Engineering and Economics of Peter the Great St. Petersburg Polytechnic University.

Статья поступила в редакцию 03.02.2025; одобрена после рецензирования 24.02.2025; принята к публикации 02.07.2025.

The article was submitted 03.02.2025; approved after reviewing 24.02.2025; accepted for publication 02.07.2025.