

## Прогнозирование российских показателей инфляции и выпуска с использованием машинного обучения

Научный руководитель – Дробышевская Лариса Николаевна

*Данков Никита Александрович*

*Аспирант*

Кубанский государственный университет, Экономический факультет, Краснодар, Россия

*E-mail: nikit.dankov@yandex.ru*

В процессе реализации денежно-кредитной политики (ДКП) особую значимость приобретает оценка перспективной ситуации в экономике. Это обусловлено лагами трансмиссионного механизма – решения по монетарной политике отражаются на экономике, как правило, спустя 3-6 кварталов. Таким образом, в условиях экономической неопределенности точность прогноза макроэкономических переменных играет существенную роль.

В данном исследовании внимание уделяется точности краткосрочных (на 3 и 6 месяцев) прогнозных оценок инфляции и выпуска, получаемых как с помощью «классического» эконометрического аппарата, так и с использованием машинного обучения (ML). Данные прогнозные значения могут быть применимы в качестве «стартовых условий» в полуструктурных квартальных прогнозных моделях, служащих для среднесрочного прогнозирования и сценарного анализа. В частности, Банк России использует одну из таких моделей в качестве основной [7].

Большинство работ по оценке эффективности прогнозов с использованием ML концентрируются в основном на показателе инфляции. При этом часть исследователей пришла к выводу, что ML-методы эффективны на длительных горизонтах прогнозирования, но в краткосрочном периоде уступают традиционным эконометрическим моделям [3]. Вопросы подходов к измерению, изучению и прогнозированию цен был посвящен семинар Банка России, РЭШ и НИУ ВШЭ [4]. В частности, для получения прогноза общего индекса инфляции, в том числе с помощью ML, может быть использован bottom-up подход, когда прогнозируются отдельные субиндексы инфляции с их последующей агрегацией в единый показатель [6]. Кроме того, помимо Росстата в качестве источников информации по инфляции могут выступать данные вебскрейпинга с сайтов розничных сетей [5], контрольно-кассовой техники [1] или из облигаций федерального займа с индексируемым на инфляцию номиналом [2].

В настоящей работе в качестве показателя инфляции используется индекс потребительских цен (ИПЦ), в качестве показателя выпуска – индекс выпуска товаров и услуг по базовым видам экономической деятельности (ИБВЭД). Представленные модели условно разделены на «классические» эконометрические (AR(1), auto ARIMA, BVAR), пространства состояний (Prophet, BSTS) и ML, которые в свою очередь разделены на модели градиентного бустинга (CatBoost, XGBoost, LightGBM) и нейронные сети (DeepAR, TFT, RNN (LSTM), PatchTST). Для моделирования искомых переменных использовался ряд показателей. Среди них данные мониторинга предприятий Банка России (индикатор бизнес-климата, текущая оценка изменения объемов производства, текущая и ожидаемая оценки изменения спроса, текущая оценка изменения цен и ценовые ожидания, оценка изменения издержек), индекс промышленного производства, оборот розничной торговли, индекс цен производителей в промышленности, денежный агрегат M2X, индекс РТС, односторонняя ставка MIACR, индекс реального эффективного курса рубля к иностранным валютам, цена нефти (на основе Brent и Urals), индекс волатильности (VIX). При этом в

таких моделях, как AR(1), auto ARIMA, Prophet и BSTS, использовались значения только искомой переменной.

Показатели представлены в приростах индекса изменения по сравнению с предыдущим месяцем (MoM, в %), а однодневная ставка MIACR и показатели мониторинга предприятий рассчитывались как разница текущего и предыдущего значений. Вместе с тем, некоторые показатели сезонно-корректировались с использованием X13-ARIMA-SEATS. Выборка включает 252 наблюдения с января 2004 года по декабрь 2024 года. Оценка прогнозной точности проводилась на различных трех- и шестимесячных интервалах 2023-2024 годов с помощью метрик RMSE и MAE.

По результатам проведенных расчетов для ИПЦ наименьшие ошибки на трехмесячном прогнозном горизонте показали модели градиентного бустинга (XGBoost, CatBoost) и AR(1). Схожие результаты отмечаются в другой работе, когда при прогнозировании инфляции на 3 и 6 месяцев ML-модели показали себя хуже базовой AR(1) модели [8]. При этом на шестимесячном прогнозном горизонте положительно выделилась нейронная сеть DeepAR. Для ИБВЭД, как более волатильного, по сравнению с инфляцией, показателя, наилучшие результаты продемонстрировали все 3 реализации градиентного бустинга, а также такие нейронные сети, как TFT и RNN (LSTM). При этом как для ИПЦ, так и для ИБВЭД, наибольшие ошибки прогноза отмечались в моделях BVAR, Prophet и BSTS. Итоговый ранжирование моделей представлен на рис. 1. Таким образом, ML-модели показали свою состоятельность при краткосрочном прогнозировании инфляции и выпуска. Вместе с тем, результаты могут быть улучшены за счет калибровки параметров моделей для снижения ошибок прогнозов конкретного выбранного показателя.

### Источники и литература

- 1) Алдохин Д., Долгов Д., Марченко П., Милютин П., Селезнев С., Шибитов Д. Измерение инфляции в России на основе гранулярных данных ККТ: презентация на XI семинаре по экономическим исследованиям Банка России, РЭШ и базовой кафедры Банка России в НИУ «Высшая школа экономики» // Банк России. 2024. URL: [http://www.cbr.ru/Content/Document/File/160135/press\\_1.pdf](http://www.cbr.ru/Content/Document/File/160135/press_1.pdf)
- 2) Андреев А., Орлов Д. Оценка вмененной инфляции из цен на индексируемые на инфляцию облигации // Банк России. 2021. URL: [https://cbr.ru/Content/Document/File/118262/methodological\\_comment\\_20210127.pdf](https://cbr.ru/Content/Document/File/118262/methodological_comment_20210127.pdf)
- 3) Букина Т.В., Кашин Д.В. Прогнозирование региональной инфляции: эконометрические модели или методы машинного обучения? // Экономический журнал Высшей школы экономики. 2024. № 1. С. 81–107. doi: 10.17323/1813-8691-2024-28-1-81-107
- 4) Грищенко В.О., Крылов И.Д. Новые подходы к измерению, изучению и прогнозированию цен: обзор совместного семинара Банка России, РЭШ и НИУ «Высшая школа экономики» // Деньги и кредит. 2024. № 2. С. 92–111
- 5) Исаков А., Латышов Р., Репин А., Постолит Е., Евсеев А., Синельникова-Мурылева Е. Твердые цифры: открытые микроданные о потребительских ценах // Деньги и кредит. 2021. № 1. С. 104–119. doi: 10.31477/rjmf.202101.104
- 6) Латышов Р., Ахмедова Е., Постолит Е., Микитчук М.Д. Прогнозирование компонент инфляции методами машинного обучения // Деньги и кредит. 2024. № 3. С. 23–44
- 7) Орлов А., Шарафутдинов А. Квартальная прогнозная модель России с рынком труда // Банк России. 2024. URL: [https://www.cbr.ru/Content/Document/File/165450/inf\\_note\\_202408.pdf](https://www.cbr.ru/Content/Document/File/165450/inf_note_202408.pdf)

- 8) Шуляк Е.С. Макроэкономическое прогнозирование с использованием данных социальных сетей // Деньги и кредит. 2022. № 4. С. 86–112

### Иллюстрации

| Модель     | ИПЦ прогноз на 3 месяца |     | ИПЦ прогноз на 6 месяцев |     | ИБВЭД прогноз на 3 месяца |     | ИБВЭД прогноз на 6 месяцев |     |
|------------|-------------------------|-----|--------------------------|-----|---------------------------|-----|----------------------------|-----|
|            | RMSE                    | MAE | RMSE                     | MAE | RMSE                      | MAE | RMSE                       | MAE |
| AR(1)      | 3                       | 3   | 2                        | 3   | 7                         | 7   | 8                          | 7   |
| auto ARIMA | 8                       | 7   | 9                        | 8   | 6                         | 6   | 9                          | 8   |
| BVAR       | 12                      | 12  | 12                       | 12  | 11                        | 11  | 10                         | 9   |
| Prophet    | 11                      | 11  | 11                       | 11  | 12                        | 12  | 12                         | 12  |
| BSTS       | 10                      | 10  | 10                       | 10  | 9                         | 10  | 11                         | 10  |
| CatBoost   | 2                       | 2   | 1                        | 1   | 2                         | 2   | 3                          | 3   |
| XGBoost    | 1                       | 1   | 5                        | 2   | 3                         | 3   | 2                          | 2   |
| LightGBM   | 5                       | 5   | 8                        | 6   | 1                         | 1   | 1                          | 1   |
| DeepAR     | 6                       | 6   | 3                        | 5   | 8                         | 8   | 6                          | 4   |
| TFT        | 7                       | 8   | 4                        | 4   | 5                         | 5   | 5                          | 5   |
| RNN (LSTM) | 4                       | 4   | 7                        | 9   | 4                         | 4   | 4                          | 6   |
| PatchTST   | 9                       | 9   | 6                        | 7   | 10                        | 9   | 7                          | 11  |

Рис. : Рис. 1 - Рэнкинг моделей по наибольшей точности прогноза