

Прогнозирование объемов кредитования с помощью моделей машинного обучения и нейронных сетей

Заявка № 1669764

Важным аспектом проведения денежно-кредитной политики является прогнозирование основных макроэкономических показателей. Центральному банку важно понимать будущие тенденции в экономической динамике для принятия корректных решений. В рамках политики инфляционного таргетирования такими решениями становятся изменения ключевой ставки, позволяющей влиять на инфляцию, подталкивая ее к достижению целевого значения. В таком случае качество прогнозов на разные горизонты оказывается важным для разработки наиболее эффективной политики центральным банком.

Одним из основных показателей экономической активности являются банковские требования к экономике. Под этим понимаются кредиты и займы, долговые ценные бумаги и прочие требования к населению, финансовым и нефинансовым организациям в рублях и иностранной валюте. Оценка данного показателя представляет интерес для центрального банка, так как связана с инфляцией и денежно-кредитными условиями через каналы процентной ставки и банковского кредитования. Чрезмерный рост объема кредитования может увеличивать совокупный спрос, создавая инфляционное давление. Чтобы иметь возможность превентивно купировать подобные риски, регулятор должен уметь прогнозировать динамику кредитования, что делает разработку наиболее точной модели для оценки данного показателя актуальным предметом исследования.

В данный момент существует множество подходов прогнозирования и наукастинга макроэкономических показателей. К ним относятся регрессионные подходы [3, 4, 13, 14, 18], динамические факторные модели (Dynamic Factor Model, DFM) [5, 7, 8, 9, 19], методы машинного обучения [2, 12, 16, 17] и другие. Нейронные сети также применяются в задаче прогнозирования, в частности способная справляться с перечисленными выше препятствиями модель долгой краткосрочной памяти (Long Short-Term Memory, LSTM). Прогнозирование квартального ВВП США с помощью данного метода показывает преимущества по сравнению с BVAR в работе [11], а смесь LSTM и DFM оказывается более точной, чем классическая DFM модель в исследовании [15]. Однако на российских данных этот метод, насколько нам известно, к прогнозированию динамики кредитования не применялся. Он использовался только для оценки таких показателей, как валовая добавленная стоимость (ВДС) отраслей промышленности [12] и инфляция [6, 17], а также при прогнозировании динамики акций на фондовом рынке [1]. В перечисленных работах прогнозирование с помощью LSTM-модели показывает более высокое качество с точки зрения ошибки прогноза по сравнению с бенчмарками (ARIMA, DFM).

Отсюда реализация продвинутых методов прогнозирования применительно к объемам кредитования становится актуальной задачей. Мы представляем способы краткосрочного прогнозирования требований к экономике с использованием моделей машинного и глубинного обучения, сравнивая их с классическими бенчмарками и регрессионными подходами. При этом требования к экономике прогнозируются в разбивке по сегментам: розничное кредитование и корпоративное. В дальнейшем прогнозируются и более детальные компоненты требований, например, в розничном сегменте рассматриваются отдельно ипотечное и неипотечное кредитование, также можно выделять автокредиты и необеспеченные потребкредиты. В корпоративном – кредиты нефинансовым компаниям, финансовым, некредитные требования и прочее.

На данный момент готовы промежуточные результаты исследования для блока розничного кредитования. Построен набор моделей машинного и глубинного обучения, а также

классические регрессионные бенчмарки. Для построения модели долгой краткосрочной памяти используется библиотека [10] в Python. Следуя методологии [12], в работе проводится предварительный отбор переменных с помощью критерия корреляции Спирмена. Сначала удаляются фичи с наибольшей связью, а затем мы оставляем только те переменные, которые в паре с таргетом показывают p -value меньше 0,1. Затем на тренировочной и валидационной выборках проводится подбор гиперпараметров с помощью перебора по сетке из встроенного в библиотеку метода и кросс-валидации, характерной для работы с временными рядами. С использованием набора гиперпараметров, показавшего наименьшую метрику MSE на тренировочной выборке, строится прогноз в винтажном стиле для каждой переменной из блока розничного кредитования: требований к населению, ипотечных и потребительских кредитов. Получено, что построенные для каждого таргета модели превосходят бенчмарки AR(1) и случайное блуждание на горизонтах от 2 до 6 месяцев. Также мы оцениваем различные варианты BVAR модели, сравнивая ее с LSTM подходом. Последняя превосходит условный прогноз BVAR на более длинных горизонтах, для требований к населению - от 4 до 6 месяцев. Далее мы проводим отбор важности признаков, выявляя те переменные, которые оказывают наибольший вклад в построении будущего прогноза. Например, для потребительского кредитования такими становятся ставка MIACR, цена барреля нефти «Юралс», ИПЦ непродовольственных товаров, номинальная заработная плата и LR кредитные ставки.

Наконец, отметим, что данные результаты актуальны для регулятора, так как позволят улучшить результаты краткосрочного прогнозирования требований к населению в разбивке по категориям заемщиков. Также при адаптации LSTM модели под ситуацию наукастинга возможно ее внедрение в макропрогноз Банка России в блок денежно-кредитных показателей.

Источники и литература

- 1) Алжеев А. В., Кочкаров Р. А. [U+200A] Сравнительный анализ прогнозных моделей ARIMA и LSTM на примере акций российских компаний // Финансы: теория и практика. – 2020. – № 1. – С. 14–23. doi: 10.26794/2587-5671-2020-24-1-14-23
- 2) Гареев М. Ю., Полбин А. В. Наукастинг: оценка изменения ключевых макроэкономических показателей с использованием методов машинного обучения // Вопросы экономики. – 2022. – № 8. – С. 133–157. doi: 10.32609/0042-8736-2022-8133-157
- 3) Макеева Н. М., Станкевич И. П. Наукастинг элементов использования ВВП России // Экономический журнал ВШЭ. – 2022. – № 4. – С. 598–622. doi: 10.17323/1813-86912022-26-4-598-622
- 4) Станкевич И. П. Применение MIDAS-моделей с марковским переключением для наукастинга ВВП и его компонентов // Прикладная эконометрика. – 2023. – № 3. – С. 122–143. doi: 10.22394/1993-7601-2023-70-122-143
- 5) Doz C., Giannone D., Reichlin L. A two-step estimator for large approximate dynamic factor models based on Kalman filtering // Journal of Econometrics. 2011. No. 164. Pp. 188–205.
- 6) Dzhunkeev, U. (2024). Forecasting Inflation in Russia Using Gradient Boosting and Neural Networks. Russian Journal of Money and Finance, 83(1), pp. 53–76.
- 7) Forni M., Hallin M., Lippi M., Reichlin L. The generalized dynamic factor model consistency and rates // Journal of Econometrics. 2004. No. 119. Pp. 231–255.
- 8) Forni M., Hallin M., Lippi M., Reichlin L. The Generalized Dynamic Factor Model // Journal of the American Statistical Association. 2005. No. 100. Pp. 830–840.

- 9) Giannone D., Reichlin L., Small D. Nowcasting: The real-time informational content of macroeconomic data // *Journal of Monetary Economics*. – 2008. – Vol. 55. – pp. 665–676. doi: 10.1016/j.jmoneco.2008.05.010
- 10) Hopp D. [U+200A]nowcast_lstm [Code for Running LSTM Neural Networks on Economic Data for Nowcasting] // *Github.com*. – 2020. URL: https://github.com/dhopp1/nowcast_lstm (дата обращения: 29.01.2024).
- 11) Hopp D. [U+200A]Economic Nowcasting with Long Short-Term Memory Artificial Neural Networks (LSTM) // *Journal of Official Statistics*. – 2022. – Vol. 38(3). – pp. 847–873.
- 12) Kryzhanovskiy, O., Mogilat, A., Shuvalova, Zh. and 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.
- 13) Kuck K., Schweikert K. Forecasting Baden-Württemberg’s GDP growth: MIDAS regressions versus dynamic mixed-frequency factor models // *Journal of Forecasting*. – 2021. – Vol. 40(5). – pp. 861–882. doi: 10.1002/for.2743
- 14) Kuzin V., Marcellino M., Schumacher C. MIDAS vs. mixed-frequency VAR: Nowcasting GDP in the euro area. // *International Journal of Forecasting*. – 2011 – Vol. 27(2). – pp. 529–542. doi: 10.1016/j.ijforecast.2010.02.006
- 15) Longo L., Riccaboni M., Rungi A. A neural network ensemble approach for GDP forecasting. *Journal of Economic Dynamics & Control*, 134 (2022), Article 104278.
- 16) Maiorova, K., Fokin, N. Nowcasting Growth Rates of Russia’s Export and Import by Commodity Groups. *Russian Journal of Money and Finance*, 80(3), pp. 34–48
- 17) Volgina, E. (2025). Forecasting Inflation Using News Indices. *Russian Journal of Money and Finance*, 84(1), pp. 26–59.
- 18) Zhang Q., Ni H., Xu H. Nowcasting Chinese GDP in a data-rich environment: Lessons from machine learning algorithms // *Economic Modelling*. – 2023. – Vol. 122. doi: 10.1016/j.econmod.2023.106204
- 19) Zubarev, A., Lomonosov, D. and 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.