

Макроэкономика

Прогнозирование инфляции с использованием высокочастотных данных в моделях временных рядов

Алина Михайловна Гребенкина*ORCID: 0000-0002-7264-5399*

Кандидат экономических наук, научный сотрудник Центра изучения проблем центральных банков, Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации (РФ, 119571, Москва, пр. Вернадского, 84)
E-mail: grebenkina-am@ranepa.ru

Елена Владимировна Синельникова-Мурылева*ORCID: 0000-0001-7494-2728*

Кандидат экономических наук, ведущий научный сотрудник Центра изучения проблем центральных банков, Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации (РФ, 119571, Москва, пр. Вернадского, 84)
E-mail: e.sinelnikova@ranepa.ru

Аннотация

В статье исследуется возможность улучшения краткосрочного прогноза инфляции при использовании высокочастотных данных о потребительских ценах в моделях временных рядов. Предпринята попытка повышения точности прогноза инфляции за счет увеличения количества наблюдений, доступных на более высокой частоте. В теоретической части работы рассмотрены преимущества и недостатки использования высокочастотных данных о ценах в моделях инфляции ADL, VAR и MIDAS, в том числе единой и смешанной частоты данных. В эмпирической части исследования анализируются последствия включения в модели прогноза индекса потребительских цен данных онлайн-индекса цен, доступных с ежедневной либо недельной частотой в 2020–2023 годах. Прогноз динамики потребительских цен, полученный в моделях VAR, MFVAR и MIDAS, включающих данные о поведении высокочастотного регрессора, сравнивается с прогнозом, полученным в одномерных бенчмарк-моделях. Вывод о различии качества краткосрочных прогнозов динамики потребительских цен в полученных моделях делается на основании различий показателей ошибки прогноза моделей. Результаты исследования свидетельствуют об улучшении в некоторых случаях качества краткосрочного вневыборочного прогноза динамики потребительских цен при учете данных об онлайн-ценах (а именно в классе многомерных моделей временных рядов при включении в модель данных на более высокой частоте). Однако с расширением горизонта прогноза ценность включения таких данных снижается. Результаты указывают на важность включения данных об онлайн-ценах в модели инфляции в дезагрегированном виде при прогнозировании ценовых тенденций ближайшего будущего.

Ключевые слова: инфляция, прогноз, ошибка прогноза, анализ данных смешанной частоты**JEL:** C22, C53, E31

Macroeconomics

Inflation Forecasting in Time Series Models Using High Frequency Data

Alina M. Grebenkina*ORCID: 0000-0002-7264-5399*Cand. Sci. (Econ.), Researcher, RANEPA,^a e-mail: grebenkina-am@ranepa.ru**Elena V. Sinelnikova-Muryleva***ORCID: 0000-0001-7494-2728*Cand. Sci. (Econ.), Lead Researcher, RANEPA,^a e-mail: e.sinelnikova@ranepa.ru^a 84, Vernadskogo pr., Moscow, 119571, Russian Federation**Abstract**

The article examines ways to improve inflation forecasting by using high frequency consumer price data in time series models. The purpose of increasing the number of observations available at a higher frequency is to increase the accuracy of inflation forecasts. The theoretical part of the paper considers the advantages and disadvantages of using high frequency price data in ADL, VAR and MIDAS inflation models with both single and mixed data frequency. The empirical section traces out the effects of including an online price index available at a daily or weekly frequency during the period from 2020 to 2023 in the forecast model for the consumer price index. The article compares the forecasts of consumer prices by applying the VAR, MFVAR and MIDAS models which include data from a high frequency regressor with the forecasts obtained through auto-ARIMA models. The conclusion about the difference in the quality of the short-term forecast of consumer price dynamics in these models is based on the difference of the forecast error indicator of the models. The results provide some evidence that short-term out-of-sample CPI dynamic forecasting becomes more accurate when online price data is included (namely in the class of multidimensional time series models when data is included in the model at a higher frequency). However, the advantage derived from including high frequency online price data in models decreases as the forecast horizon is extended. The results show the importance of including online price data in inflation models in a disaggregated form while forecasting price trends of the nearest future.

Keywords: inflation, forecast, forecast error, mixed frequency data models**JEL:** C22, C53, E31

Acknowledgements

The article was written on the basis of the RANEPA state assignment research programme.

Введение

Онлайн-цены — альтернативный источник информации, который стал доступен для исследовательских целей по мере накопления ретейлерами информации об интернет-транзакциях. В настоящее время этот массив данных может быть использован при прогнозировании инфляции.

Данные об онлайн-ценах могут внести положительный вклад в результаты классических моделей прогноза инфляции. Во-первых, эти данные характеризуются более высокой частотой измерения, а значит, содержат больше информации для обработки статистическими методами (как показано, например, в работе Альберто Кавалло и Роберто Ригобона [Cavallo, Rigobon, 2016]). Во-вторых, эти данные доступны в режиме реального времени и уже сегодня содержат информацию, которая будет отражена в официальной статистике с лагом (продемонстрировано в работе Диего Апарисио и Мануэля Бертолотто [Aparicio, Bertolotto, 2020]). В-третьих, в работе Александры Божечковой и Алексея Евсеева [Божечкова, Евсеев, 2020] отмечено, что для онлайн-цен характерна меньшая жесткость, а значит, постепенное изменение цен формирует ценовую тенденцию раньше, чем ее демонстрирует официальный Индекс потребительских цен (далее — ИПЦ).

Вместе с тем добавление высокочастотных данных может внести нежелательную зашумленность в прогнозную модель, а значит, сделать прогноз инфляции менее точным. Также следует отметить технические и методологические сложности сбора данных об онлайн-ценах. В работе Алексея Евсеева и соавторов [Евсеев и др., 2022] показано, что прежде всего это касается необходимости поддержания высокой степени непрерывности рядов индексов цен во времени, контроля качества разметки данных, обеспечения экологичного извлечения данных.

В связи с этим авторами настоящей статьи проверяется гипотеза о возможности улучшения прогноза официальной инфляции при включении в модели данных об онлайн-ценах и значимость этого улучшения.

1. Обзор литературы о преимуществах и недостатках моделей инфляции с использованием высокочастотных данных

Данные об онлайн-ценах могут быть включены в модели прогноза инфляции несколькими стандартными способами, а именно при помощи моделей ADL, VAR и MIDAS.

Для прогнозирования инфляции в настоящей работе выбран класс многомерных моделей временных рядов, точность про-

гноза которых сравнивается с точностью прогноза одномерных бенчмарк-моделей временных рядов. Выбранный класс моделей позволяет учесть при прогнозировании стандартные объясняющие переменные инфляции. Особенно востребованным учет факторов инфляции может быть для целей краткосрочного прогнозирования в периоды повышенной макроэкономической неопределенности и динамично меняющегося информационного контекста. В работах Фетхи Огюнца и соавторов [Ögünç et al., 2013], Либерио Монтефорте и Джанлуки Моретти [Monteforte, Moretti, 2013], Дианы Габриелян [Gabrielyan, 2019] и других показано, что прогностические свойства моделей ADL, VAR и MIDAS при прогнозе на краткосрочный период или в ситуации повышенной макроэкономической неопределенности лучше, чем у одномерных технических моделей. Схожий вывод получен в работе Юрия Перевышина [Перевышин, 2022], в которой прогнозируется инфляция в России при помощи многомерной модели временных рядов¹.

Первым способом учета онлайн-цен является их включение в ADL-модель официальной инфляции вида:

$$\pi_t = c + t + \alpha\pi_{t-1} + \beta(L)x_t^L + \gamma z_t + \varepsilon_t, \quad (1)$$

где π_t — показатель инфляции (измеряемый с месячной частотой), c — константа модели, t — тренд, x_t^L — высокочастотный регрессор (индекс онлайн-цен, измеряемый с дневной частотой), агрегированный до месячных данных простым усреднением, $\beta(L)$ — оператор запаздывания высокочастотного регрессора x_t^L , z_t — прочие контрольные переменные модели, ε_t — ошибки модели.

Если контрольные переменные модели z_t включают данные о безработице, деловой активности, выпуске и т.п., то ADL-модель (1) представляет собой одну из возможных спецификаций кривой Филлипса [Gabrielyan, 2019]. Параметры модели (1) оцениваются методом наименьших квадратов. Недостатком метода является потеря информации, которую содержит высокочастотный регрессор, поскольку агрегирование данных до низкой частоты предполагается методом простого усреднения.

Вторым способом учета онлайн-цен является их включение в VAR-модель (в структурной форме (2) и в приведенной форме (3)):

¹ Выбор класса многомерных моделей временных рядов в настоящей работе также был обусловлен ограниченностью массива данных индекса цен онлайн-ритейлеров трехлетним периодом. В частности, ограничение доступного массива данных не позволяет использовать для построения прогнозной модели с главными компонентами модели нейронных сетей и др.

$$B_0 y_t = B_1 y_{t-1} + \dots + B_p y_{t-p} + u_t \Sigma_u = I_k, \quad (2)$$

$$y_t = A_1 y_{t-1} + \dots + A_p y_{t-p} + \varepsilon_t \varepsilon_t = B_0^{-1} u_t \Sigma_u = B_0^{-1} B_0^{-1'}, \quad (3)$$

где y_t — векторы k переменных модели, в том числе низкочастотного показателя инфляции и высокочастотного регрессора (данных об онлайн-ценах, измеряемых с дневной частотой), агрегированного до месячных данных простым усреднением, p — порядок лага модели, A , B — матрицы коэффициентов модели, u_t — вектор структурных шоков, ε_t — вектор инноваций, Σ_u — ковариационная матрица вектора структурных шоков, Σ_ε — ковариационная матрица вектора инноваций. В отличие от ADL-модели VAR-модель позволяет проверить наличие прямой и обратной связи между онлайн-данными и данными официальной статистики, а также снизить риски эндогенности, обусловленной подобной связью данных. С использованием VAR-модели в работах [Aparicio, Bertolotto, 2020; Cavallo, Rigobon, 2016] показано, что онлайн-данные цен обладают некоторым «предвосхищающим эффектом», то есть учитывают информацию, которая отражается в данных официальной инфляции спустя несколько месяцев. Полученный авторами названных работ результат оказался устойчив для десяти развитых стран.

Простые ADL- и VAR-модели предполагают необходимость усреднения высокочастотных данных по онлайн-ценам, что приводит к потере информации. Эту проблему позволяет решить подход MIDAS, разработанный для работы с массивами данных разной частоты. В частности, метод используется для прогноза квартального ВВП на основе ежемесячных опережающих индикаторов (например, в работе Владимира Кузина и соавторов [Kuzin et al., 2011]); прогноза недельной волатильности фондового рынка на основе дневных данных (в работе Джевдета Алпера и соавторов [Alper et al., 2012]); прогноза месячной инфляции на основе дневных данных о ценах (в работе Йорга Брайтунга и Кристофа Ролинга [Breitung, Roling, 2015]). В общем виде MIDAS-регрессия может быть записана как

$$A(L)\pi_t = c + B(L^{1/m})x_t^{(m)} + \varepsilon_t, \quad (4)$$

где π_t — низкочастотная переменная (показатель инфляции, измеряемый с месячной частотой), $A(L)$ — оператор запаздывания низкочастотной переменной (с максимальным лагом запаздывания p), x_t — высокочастотная переменная (индекс онлайн-цен, измеряемый с дневной частотой), $B(L^{1/m})$ — оператор запаздывания

высокочастотной переменной (с максимальным лагом запаздывания l), m — отношение наблюдения высокочастотной переменной к низкочастотной переменной², c — константа модели, ε_t — ошибки модели.

Стандартная MIDAS-модель предлагает параметрический подход к работе с высокочастотными данными. Для высокочастотной переменной рассчитываются полиномы распределенного запаздывания. Если в случае простого агрегирования высокочастотных данных каждое наблюдение учитывается с одинаковым весом, то в случае MIDAS-подхода вес каждого наблюдения определяется формой полинома. Таким образом, MIDAS-подход позволяет учесть больше информации о высокочастотной переменной, чем методы, предполагающие простое усреднение высокочастотных данных.

Модель (4) может быть оценена с помощью стандартных подходов, применяемых к оценке временных рядов, либо с помощью инструментов байесовской статистики. В частности, если на модель (4) не наложены ограничения (unrestricted MIDAS), то она может быть оценена при помощи обычного метода наименьших квадратов. Однако модель без ограничений будет давать плохие результаты, если сумма параметров $d = p_{max} + l_{max}$ слишком велика относительно числа наблюдений (доступных на самой низкой частоте), что характерно для этого класса моделей. Это объясняется тем, что в экономических данных последовательные лаги обычно сильно коррелированы, а значит, включение в модель значительного количества параметров будет приводить к мультиколлинеарности и ухудшению оценок модели.

Для решения указанной проблемы авторами MIDAS-подхода — Эриком Гизелсом и соавторами [Ghysels et al., 2007] — предложено наложение ограничения на параметры полинома запаздывания $B(L^{1/m})$ для высокочастотной переменной. Функция ограничения f выбирается на усмотрение исследователя. Наложение ограничения приводит к снижению числа параметров регрессии до $q < d$ и $q < n$. В работе [Ghysels et al., 2016] показано, что наложение ограничения позволяет значительно снизить ошибки вневыборочного прогноза модели, особенно в случае, если размер выборки низкочастотной переменной мал.

Функция ограничения f задает схему взвешивания распределенных лагов высокочастотного показателя:

² Например, $m = 12$, если низкочастотная переменная наблюдается с годовой частотой, а высокочастотная переменная — с месячной частотой; $m = 4$, если низкочастотная переменная наблюдается с месячной частотой, а высокочастотная переменная — с недельной частотой.

$$f(\cdot) = \lambda w_p(\delta_p, s), \quad (5)$$

где $w_p(\cdot)$ — функция взвешивания, λ — параметр взаимодействия (impact parameter), δ_p — вектор параметров, меняющихся в зависимости от порядка лага низкочастотной переменной $p \in \{1 \dots p_{max}\}$, $s \in N$ — индекс.

В качестве функции взвешивания в MIDAS-моделях может использоваться ступенчатая функция (STEP), функция взвешивания Алмон (она же PDL-функция), экспоненциальная функция взвешивания Алмон, функция взвешивания бета, логарифмическое распределение Коши, функция Гомпертца и другие [Ghysels et al., 2007; 2016].

Хотя ограничение для MIDAS-модели позволяет преодолеть проблему мультиколлинеарности и учесть больше информации от высокочастотного регрессора, чем при его простом усреднении, MIDAS-подход имеет ограничения. Выбор функции взвешивания f может быть гибким и субъективным. Решением проблемы может быть комбинирование прогноза с использованием различных схем взвешивания (например, EW, BICW, AICW, MSFE и др.)³.

Дискуссионным остается вопрос, являются ли MIDAS-модели инструментом улучшения прогнозной способности моделей, поскольку высокочастотные данные привносят не только новую информацию, но и дополнительную зашумленность в модель. Согласно выводам работы Марты Банбура и соавторов [Banbura et al., 2010], MIDAS-модели полезны по крайней мере для краткосрочного прогнозирования или наукастинга. Согласно позиции Кавалло [Cavallo, 2017], по мере распространения интернет-торговли происходит выравнивание цен онлайн- и офлайн-ритейлеров, а значит, онлайн-данные по ценам со временем становятся надежным предиктором официального ИПЦ в рамках наукастинга.

Несмотря на некоторые преимущества, серьезным недостатком MIDAS-подхода является сохранение проблемы эндогенности в данных. С целью решения этой проблемы разработаны инструментарий VAR-моделей смешанной частоты (mixed-frequency VAR, или MFVAR), например в работах Эрика Гизелса [Ghysels, 2016] и Франка Шорфхайде и Донхо Сон [Schorfheide, Song, 2013]. Оценка MFVAR-модели может быть произведена при помощи U-MIDAS-модели, если количество

³ EW (equal weights) — простое среднее, BICW (Bayesian information criteria weights) — байесовское взвешивание, AICW (Akaike information criteria weights) — взвешивание по критерию Акаике, MSFE (mean squared forecasting error) — взвешивание на основании среднеквадратичной ошибки прогноза.

параметров модели не критично растет в результате добавления высокочастотного регрессора. В других случаях для оценки MFVAR-модели может потребоваться наложение ограничения (например, в виде функции взвешивания Алмон) либо применение методов байесовской статистики.

Для постановки MFVAR-модели (например, как в работе [Ghysels, 2016]) задается K -мерный процесс. Первые $K_L < K$ элементов формируют векторный процесс $x_L(\tau_L)$, следующие $K_H = K - K_L$ элементов формируют векторный процесс $x_H(\tau_L, k_H)$. Векторный процесс $x_L(\tau_L)$ наблюдается на периодах низкой частоты τ_L ; векторный процесс $x_H(\tau_L, k_H)$ — на периодах высокой частоты $k_H = 1, \dots, m$ в течение периода τ_L . В этом случае MFVAR-модель задается как

$$\begin{pmatrix} x_H(\tau_L, 1) \\ \vdots \\ x_H(\tau_L, m) \\ x_L(\tau_L) \end{pmatrix} = A_0 + \sum_{j=1}^p A_j \begin{pmatrix} x_H(\tau_{L-j}, 1) \\ \vdots \\ x_H(\tau_{L-j}, m) \\ x_L(\tau_{L-j}) \end{pmatrix} + \varepsilon(\tau_L), \quad (6)$$

где A_0, A_j — матрицы коэффициентов модели, $x_L(\tau_L)$ — низкочастотный процесс (например, показатель инфляции, измеряемый с месячной частотой), $x_H(\tau_L, k_H)$ — высокочастотный процесс (например, индекс онлайн-цен, измеряемый с дневной или недельной частотой), p — количество низкочастотных лагов модели, m — отношение наблюдения высокочастотной переменной к низкочастотной переменной, $K = K_L + mK_H$ — размерность модели.

MFVAR-подход объединяет преимущества MIDAS-подхода (дает возможность учесть информацию, доступную с большей частотой) и преимущества VAR-подхода (учитывающего взаимосвязь макроэкономических переменных). К недостаткам метода можно отнести невозможность оценки модели при малом количестве низкочастотных данных относительно количества высокочастотных данных, а также меньшее разнообразие методов оценки в сравнении с MIDAS-регрессией.

Преимущества и недостатки описанных выше методов прогнозирования инфляции сгруппированы в табл. 1.

2. Индекс цен онлайн-ритейлеров

Для целей настоящей работы в качестве объясняющего высокочастотного регрессора рассматривался индекс цен онлайн-

Т а б л и ц а 1

**Эконометрические методы прогноза офлайн-инфляции
с использованием данных по онлайн-ценам**

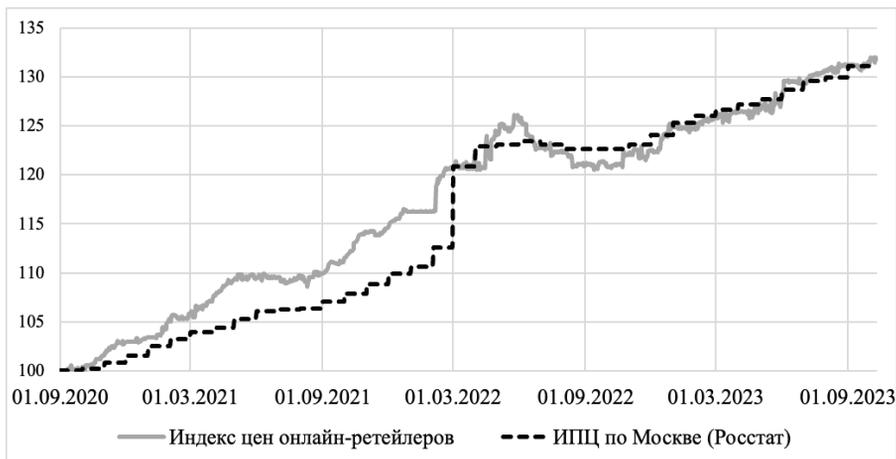
T a b l e 1

**Econometric Methods for Forecasting Offline Inflation
Using Online Price Data (Summary)**

Метод	Публикация	Преимущества метода	Недостатки метода
ADL-модель	[Gabrielyan, 2019]	Включение высокочастотного регрессора в модель методом простого усреднения	Потеря информации в результате агрегирования высокочастотного регрессора
VAR-модель	[Aparicio, Bertolotto, 2020; Cavallo, Rigobon, 2016]	Возможность учета проблемы эндогенности при включении высокочастотного регрессора в модель методом простого усреднения	до переменной самой низкой частоты
MIDAS-модель	[Ghysels et al., 2007]	Использование высокочастотных данных без потери информации в результате агрегирования	Риск мультиколлинеарности в модели без ограничений; чувствительность результата прогноза к выбору функции ограничения
MFVAR-модель	[Ghysels, 2016; Schorfheide, Song, 2013]	Возможность учета проблемы эндогенности при включении высокочастотного регрессора в исходном виде	Меньшее разнообразие методов оценки по сравнению с MIDAS-моделями

Источник: составлено авторами.

ритейлеров Москвы, рассчитываемый с сентября 2020 года на ежедневной основе. При построении индекса учитываются товары — представители продовольственных и непродовольственных категорий, пользующиеся широким спросом у населения. Используются фактические цены в Москве, которые далее формируют динамические ряды цен по различным категориям. Для обеспечения сопоставимости высокочастотного индекса с официальными данными ИПЦ применяются веса Росстата. Более подробная методологическая информация приведена в работах Александра Исакова и соавторов [Исаков и др., 2021] и Натальи Дьяковой [Дьякова, 2023]. Сравнение данных индекса цен онлайн-ритейлеров и ИПЦ по Москве представлено на рис. 1.



Источник: [Дьячкова, 2023].

Рис. 1. Индекс цен онлайн-ритейлеров и индекс потребительских цен в Москве (пункты)

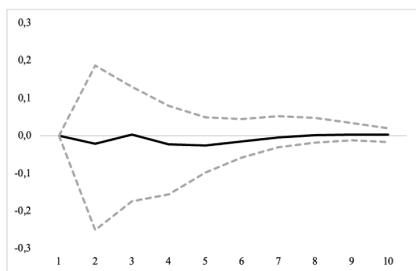
Fig. 1. Online Retailers Price Index and the Consumer Price Index for Moscow (points)

В работе [Cavallo, 2017] высказывается предположение, что онлайн-данные и данные официальной инфляции часто оказываются связанными, и в таком случае использование онлайн-данных способно увеличить количество доступных наблюдений прогнозной модели инфляции, а значит, сделать прогноз более точным. Построение структурной модели векторной авторегрессии для показателей, взятых в первых разностях (официального ИПЦ по Москве, индекса цен московских онлайн-ритейлеров, номинального курса рубля и ставки процента денежного рынка⁴), показывает, что отклик первых разностей официального ИПЦ на шок первых разностей онлайн-цен значимо положительный в краткосрочном периоде, тогда как обратный отклик незначим⁵. Согласно результатам теста на причинность, проведенного для этой же спецификации, ряд первых разностей онлайн-цен является причиной по Грейнджеру для ряда первых разностей официального ИПЦ, тогда как обратное не подтверждается (табл. 2). Иными словами, можно предположить, что некоторая информация о ценах быстрее отражается в данных онлайн-цен, и учет этой информации может быть полезен при прогнозировании официальной инфляции (рис. 2).

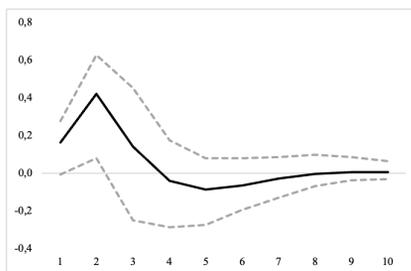
⁴ В следующем разделе статьи эта модель обозначена как модель Б.

⁵ Модель построена для переменных, взятых в первых разностях (37 месячных наблюдений), на стационарных рядах согласно результатам проведенного теста Дики — Фуллера на наличие единичного корня. Согласно результатам теста Энга — Грейнджера исходные временные ряды (официальный ИПЦ и индекс цен онлайн-ритейлеров) не являются коинтегрированными. В соответствии с информационным критерием Шварца выбран порядок модели $p = 1$. Согласно графику коррелограммы остатков автокорреляция ошибок в модели отсутствует.

а) Отклик первых разностей индекса онлайн-цен на шок первых разностей официального ИПЦ



б) Отклик первых разностей официального ИПЦ на шок первых разностей онлайн-цен



Примечание. Пунктирными линиями представлен 95-процентный бутстреп доверительный интервал точечной оценки импульсного отклика. Горизонт импульсного отклика составляет 10 месяцев.

Источник: рассчитано авторами.

Рис. 2. Импульсные отклики индекса цен онлайн-ритейлеров и индекса потребительских цен в Москве, полученные в SVAR-модели

Fig. 2. Impulse Response Functions of the Online Retailers Price Index and the Consumer Price Index for Moscow Derived From the SVAR Model

Т а б л и ц а 2

Результаты теста Грейнджера на причинность, полученные в SVAR-модели

Table 2

Granger Causality Test Derived From the SVAR Model

Направление влияния	p -значение для теста нулевых ограничений
Первые разности индекса онлайн-цен → первые разности официального ИПЦ	0,002 (F-статистика = 11,231)
Первые разности официального ИПЦ → первые разности индекса онлайн-цен	0,885 (F-статистика = 0,021)

Источник: рассчитано авторами.

3. Построение прогнозных моделей инфляции с использованием данных об онлайн-ценах

Для проверки гипотезы о возможности использования данных об онлайн-ценах для улучшения прогноза инфляции в моделях временных рядов авторами построены следующие модели.

В качестве модели-бенчмарка построены $ARIMA(p, d, q)$ -модель для индекса потребительских цен и $ARIMAX(p, d, q)$ -модель, предполагающая добавление в качестве объясняющего регрессора данных о ценах онлайн-ритейлеров, агрегированных до месячной частоты. Параметры бенчмарк-модели выбирались автоматиче-

ски. С этими моделями далее сравниваются многомерные модели временных рядов А–Д:

— А — модель структурной векторной авторегрессии (SVAR-модель), включающая стандартные факторы инфляции: номинальный валютный курс рубля и ставку процента денежного рынка MIACR. Структуризация модели осуществлена на основе идентификации по Холецкому в порядке, в котором перечислены переменные. Модель А используется в качестве модели-бенчмарка в классе многомерных моделей временных рядов и не содержит данных об онлайн-ценах;

— Б — SVAR_{online}-модель, включающая как стандартные факторы инфляции, так и данные об онлайн-ценах на низкой частоте;

— В — модель векторной авторегрессии смешанной частоты (MFVAR-модель), включающая стандартные факторы инфляции на низкой частоте и более высокочастотные данные об онлайн-ценах, чем модель Б;

— Г — модель смешанной частоты (ADL-MIDAS-модель), включающая более высокочастотные данные об онлайн-ценах, чем модель Б (ADL-компонент получен в результате включения в модель первого лага зависимой переменной);

— Д — модель смешанной частоты (ADL-MIDAS-модель), включающая более высокочастотные данные об онлайн-ценах, чем модель Б, а также данные о стандартных факторах инфляции на низкой частоте.

Модели А и Б — это модели векторной авторегрессии единой частоты, которые могут быть записаны в общем виде, как показано в выражениях (2) и (3). Модель В — это модель смешанной частоты, которая может быть записана в общем виде, как показано в выражении (6). Модели Г и Д — это модели смешанной частоты, которые могут быть записаны в общем виде, как показано в выражении (4).

Описание данных, использованных для построения моделей инфляции, представлено в табл. 3.

Доступный для исследования массив данных ограничен периодом сбора данных о ценах онлайн-ритейлеров, то есть 37 месячными наблюдениями низкочастотного регрессора, или 1125 дневными наблюдениями высокочастотного регрессора. Для некоторых моделей высокочастотный регрессор был частично агрегирован до недельной частоты, то есть до 161 доступного наблюдения. Все регрессоры включены в модели А–Д в первых разностях. Согласно тесту Дики — Фуллера на наличие единичного корня, все временные ряды стационарны в первых разностях.

Т а б л и ц а 3

**Данные и частота данных,
использованных в моделях прогноза инфляции А-Д**

T a b l e 3

Data and Frequency of Data Used in Inflation Forecast Models A-E

Переменная	Описание переменной	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Группа моделей Г и Д (ADL-ADL-MIDAS)	Ожидаемый знак влияния на зависимую переменную CPI
Индекс потребительских цен, Москва (CPI) (пункты)	Росстат, сентябрь 2020 = 100, n = 37 (месяцы)	+	+	+	+	
Онлайн-индекс цен, Москва (Online) (пункты)	Сентябрь 2020 = 100, n = 1125 (дни)				+	+
Онлайн-индекс цен, Москва (Online) (пункты)	Сентябрь 2020 = 100, n = 161 (недели)			+	+	+
Онлайн-индекс цен, Москва (Online) (пункты)	Сентябрь 2020 = 100, n = 37 (месяцы)		+			+
Номинальный курс рубля к доллару (Rub) в прямой котировке (руб./долл.)	Данные Банка России, n = 37 (месяцы)	+	+	+	+	+
Ставка процента денежного рынка MIACR (Miacr) (%)	Данные Банка России, n = 37 (месяцы)	+	+	+	+	-

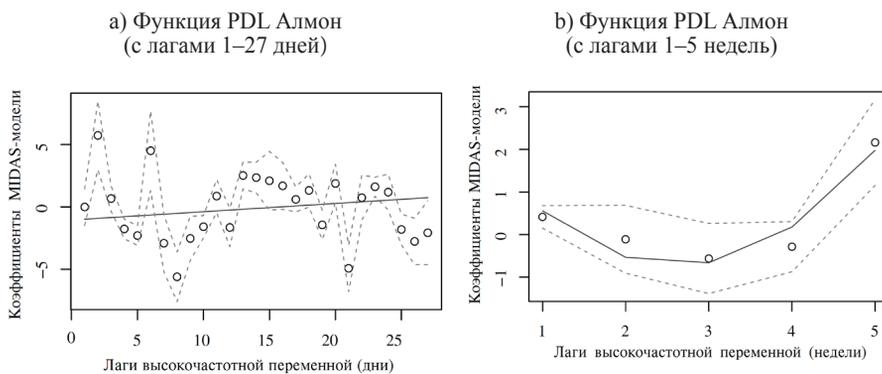
Источник: составлено авторами.

При построении MIDAS-моделей авторы столкнулись с проблемой выбора подходящего функционального ограничения и степени агрегирования переменной интереса. Результаты построения MIDAS-модели показали, что включение индекса онлайн-цен в модель прогноза официальной инфляции с исходной дневной частотой нецелесообразно. Согласно данным рис. 3а в этом случае функциональное ограничение не может повторить фактическое распределение значимых лагов высокочастотной переменной, полученных в MIDAS-модели без ограничения (обозначены на рис. 3 внутри доверительного интервала). Авторам не удалось получить удовлетворительное функциональное ограничение при переборе стандартных функций взвешивания. Это может быть связано с тем, что ежедневные изменения индекса онлайн-цен малы, а в значительном числе случаев равны нулю.

В силу неудовлетворительных результатов на дневных данных индекс онлайн-цен был агрегирован до недельной частоты. На этой частоте было подобрано несколько функциональных ограничений, описывающих фактическое распределение лагов высокочастотного регрессора в модели без ограничений (например, функция PDL Алмон, рис. 3б). Отбор функциональных ограничений для MIDAS-

моделей проходил в соответствии с рекомендациями, изложенными в работе [Ghysels et al., 2016], по трем критериям:

- 1) наличие успешной сходимости оптимизации при заданном функциональном ограничении;
- 2) удовлетворение функционального ограничения тесту на адекватность спецификации в соответствии с методологией, представленной в работе Вирмантаса Кведараса и Вайдотаса Землиса [Kvedaras, Zemlys, 2012];
- 3) наличие минимального значения информационного критерия (Акаике или Шварца).



Примечание. Сплошная линия — функциональное ограничение, оцененное в MIDAS-модели; точки — оценка коэффициентов лагов высокочастотного регрессора в MIDAS-модели без ограничения, пунктирные линии — 95-процентный доверительный интервал точечной оценки коэффициентов.

Источник: рассчитано авторами.

Рис. 3. Подбор функционального ограничения для MIDAS-моделей, где высокочастотный регрессор измерен на среднедневной (а) и средненедельной (б) частоте

Fig. 3. Application of a Constraint Function for MIDAS Models Where the High Frequency Regressor Is Measured With the Daily Average Frequency (a) or Weekly Average Frequency (b)

Отбор функциональных ограничений проводился перебором для четырех функций взвешивания (PDL-функции, бета-функции, экспоненциальной функции Алмон и функции Гомпертца). Для каждой функции перебиралась комбинация лагов высокочастотного регрессора: от 0 до 12 недельных лагов, от 1 до 12 недельных лагов, от 2 до 12 недельных лагов (итого было рассмотрено 122 функциональных ограничения).

По результатам отбора всем указанным критериям в группе моделей Γ удовлетворяли три функциональных ограничения: функция PDL Алмон с лагами 1–5 недель, экспоненциальная функция Алмон с лагами 0–4 недели, функция Гомпертца с лага-

ми 1–7 недель. В группе моделей Д всем критериям удовлетворяли также три функциональных ограничения: функция PDL Алмон с лагами 0–4 недель, экспоненциальная функция Алмон с лагами 0–4 недели, функция Гомпертца с лагами 0–5 недель.

Результаты оценивания моделей А–Д представлены в табл. 4. Знаки значимых коэффициентов моделей при регрессорах соответствуют предположениям, изложенным в табл. 3.

Для сравнения качества прогнозов моделей А, Б, В, Г и Д использован показатель среднеквадратичной ошибки RMSE (root mean square error), рассчитанный по формуле (7):

$$RMSE = \sqrt{\frac{1}{n} \sum_{h=1}^n (\hat{p}_{t+h/t} - p_{t+h})^2}, \quad (7)$$

где h — горизонт прогнозирования зависимой переменной, t — момент прогнозирования, $\hat{p}_{t+h/t}$ — прогноз зависимой переменной, p_{t+h} — фактическое значение зависимой переменной.

Краткосрочный вневыборочный прогноз официального ИПЦ в первых разностях построен итеративно в моделях А–Д на 1 и на 3 месяца вперед. Прогнозы, полученные в рамках групп моделей Г и Д, комбинировались из результатов, полученных в трех отобранных функциональных ограничениях, в соответствии со схемами EW и MSFE. Из-за сравнительно небольшого количества низкочастотных наблюдений обучающая выборка строилась по методу расширяющегося окна для последних 15 месяцев выборки (с июля 2022 по сентябрь 2023 года). При каждом изменении окна модели пересчитывались. Результаты оценки RMSE-прогнозов моделей на 1 месяц вперед представлены в табл. 5, на 3 месяца вперед — в табл. 6.

Согласно данным табл. 5 и 6, одномерные модели демонстрируют лучшие прогнозные характеристики, чем многомерные. Добавление данных об онлайн-ценах в бенчмарк-модель несколько снижает ошибку прогноза на горизонте 1 месяца, но не снижает — на горизонте 3 месяцев. В классе многомерных моделей временных рядов включение данных об онлайн-ценах в модели инфляции в среднем приводит к снижению ошибки прогноза на 1 месяц вперед, при этом для прогнозирования на 3 месяца вперед результаты более противоречивы. Включение информации о валютном курсе в группу моделей Д увеличивает ошибку прогноза в сравнении с результатами, полученными в группе моделей Г.

Для проверки статистической значимости различия качества рассматриваемых прогнозов проведен тест Диболда — Мариано (далее — DM-тест). В качестве аргумента для DM-теста использо-

Т а б л и ц а 4

Оценка регрессоров в моделях А–Д

T a b l e 4

Regressors for Models A–E

Регрессор модели	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Группа моделей Г (ADL-ADL-MIDAS)			Группа моделей Д (ADL-ADL-MIDAS)		
						функция PDL Алмон	экспоненциальная функция Алмон	функция Гомпертца	функция PDL Алмон	экспоненциальная функция Алмон	функция Гомпертца
<i>dCPI(-1)</i>			1,293*** (0,161)	0,724*** (0,222)	0,430*** (0,203)	0,162*** (0,039)	0,296*** (0,067)	0,213*** (0,047)	0,579** (0,238)	0,566* (0,278)	0,566** (0,217)
<i>dRub(-1)</i>			0,318*** (0,024)	0,197*** (0,035)	0,107*** (0,036)				0,127** (0,049)	0,139** (0,060)	0,139*** (0,045)
<i>dMiacr(-1)</i>			-0,493*** (0,101)	-0,184 (0,128)	-0,030 (0,119)				-0,167 (0,131)	-0,111 (0,151)	-0,111 (0,129)
<i>dOnline(-1)</i>		0,736*** (0,187)		0,344* (0,157)							
<i>dOnline_1w(-1)</i>					-0,058 (0,2763)						
<i>dOnline_2w(-1)</i>					-0,326 (0,406)						
<i>dOnline_3w(-1)</i>					1,569*** (0,346)						
<i>dOnline_4w(-1)</i>					-0,445 (0,306)						
θ_1						2,614*** (0,810)	0,894*** (0,478)	2,471*** (0,380)	1,668*** (0,537)	1,118*** (0,346)	1,118*** (0,349)
θ_2						-2,536*** (0,876)	0,941 (3,641)	0,002 (1,012)	-1,598*** (0,538)	8,530 (15,61)	-1,311 (3,842)
θ_3						0,482*** (0,166)		8,843 (10,445)	0,303*** (0,095)		3,138 (2,333)
<i>Phi_1</i>	0,331** (0,155)	0,313** (0,158)									
<i>Const</i>	0,860*** (0,311)	-0,237 (0,307)	0,086 (0,186)	-0,116 (0,210)	0,285** (0,193)	0,195 (0,213)	0,540* (0,173)	0,061 (0,266)	0,299 (0,207)	0,327* (0,202)	0,327 (0,274)
<i>Trend</i>						0,0166 (0,011)	-0,002 (0,006)	0,009 (0,007)	-0,006 (0,009)	-0,001 (0,009)	-0,001 (0,001)
<i>R2adj</i>	0,11	0,368	0,902	0,667	0,776	0,719	0,082	0,479	0,781	0,768	0,759

Примечания: 1. Зависимая переменная — данные официального ИПЦ по Москве в первых разностях (*dCPI*). 2. В скобках указаны стандартные ошибки коэффициентов. 3. *Phi* — коэффициент авторегрессионной модели; θ — коэффициенты, определяющие значимость параметров соответствующего функционального ограничения MIDAS-регрессии; *dOnline_w* — первая разность недельных данных индекса онлайн-цен (первой, второй, третьей, четвертой недели месяца соответственно); *R²adj* — скорректированный коэффициент детерминации. 4. Количество лагов в моделях выбрано с учетом информационных критериев. 5. «*», «**» и «***» обозначают значимость коэффициентов моделей на 10-, 5- и 1-процентном уровне значимости соответственно.

Источник: рассчитано авторами.

ваны временные ряды, состоящие из последовательно рассчитанных прогнозных значений на 1 и на 3 месяца вперед, полученных в моделях А–Д. В табл. 7 и 8 представлены *p*-значения DM-теста, проведенного попарно для рядов прогнозных значений из моделей А–Д. Для расчета DM-статистики теста использована U-образная функция потерь и произведена поправка на малый размер выборки прогнозных значений. На рис. 4 представлены отклонения прогнозных значений первой разности официального ИПЦ от фактических значений на горизонте 1 и 3 месяцев.

Т а б л и ц а 5

**Сравнение ошибки краткосрочных прогнозов официального ИПЦ
на 1 месяц вперед в различных прогнозных моделях на основании значения RMSE**

T a b l e 5

**Comparison of Short-Term Errors in the Official CPI Forecasts for the Next Month
Using Various Forecast Models Based on RMSE Value**

Прогноз на	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVARonline)	Модель В (MFVAR)	Группа моделей Г (ADL-MIDAS)		Группа моделей Д (ADL-MIDAS)	
						схема EW	схема MSFE	схема EW	схема MSFE
сентябрь 2023	0,48	0,48	0,54	1,20	0,45	1,07	0,16	0,82	0,82
август 2023	0,48	0,05	1,97	1,32	1,40	0,72	0,66	1,23	1,23
июль 2023	0,02	1,12	1,29	1,92	0,20	0,63	0,59	0,44	0,44
июнь 2023	0,20	0,06	0,91	1,48	1,28	1,02	0,75	1,58	1,40
май 2023	0,16	0,21	1,33	0,83	0,28	0,32	0,05	0,24	0,03
апрель 2023	0,25	0,17	0,80	0,23	0,55	0,02	0,08	0,37	0,37
март 2023	0,27	0,01	1,28	0,42	0,63	1,02	0,91	0,72	0,72
февраль 2023	0,26	0,50	1,96	2,16	1,19	0,02	0,14	1,18	1,09
январь 2023	0,34	0,06	1,70	1,66	1,93	0,51	0,50	1,54	1,52
декабрь 2022	0,22	0,01	0,43	0,25	0,01	0,49	0,48	0,25	0,15
ноябрь 2022	0,15	0,04	0,17	0,15	0,38	0,08	0,01	0,14	0,02
октябрь 2022	0,57	0,05	0,18	0,34	0,25	0,30	0,36	1,22	0,17
сентябрь 2022	0,55	0,44	0,51	0,48	0,22	0,15	0,10	0,16	0,01
август 2022	1,01	0,66	0,95	0,43	0,91	0,70	0,59	1,14	1,08
июль 2022	1,33	1,83	0,39	0,09	0,42	0,34	0,23	0,39	0,38
Среднее RMSE	0,42	0,38	0,96	0,86	0,67	0,49	0,37	0,69	0,63

Примечание. В качестве даты прогноза указана дата, на которую сделан прогноз (например, для строки «сентябрь 2023» указана величина ошибки вневывборочного прогноза, сделанного в августе 2023 года на 1 месяц вперед).

Источник: рассчитано авторами.

Т а б л и ц а 6

**Сравнение ошибки краткосрочных прогнозов официального ИПЦ
на 3 месяца вперед в различных прогнозных моделях на основании значения RMSE**

T a b l e 6

**Comparison of Short-Term Forecast Errors in the Official CPI Forecasts for the Next Three Months
Using Various Forecast Models Based on RMSE Value**

Прогноз на	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Группа моделей Г (ADL-MIDAS)		Группа моделей Д (ADL-MIDAS)	
						схема EW	схема MSFE	схема EW	схема MSFE
сентябрь 2023	0,33	0,71	0,96	1,19	0,46	0,46	0,42	1,01	0,96
август 2023	0,29	0,67	0,62	1,03	0,79	0,44	0,37	1,17	1,13
июль 2023	0,12	0,63	0,84	0,62	0,71	0,22	0,23	0,95	0,88
июнь 2023	0,21	0,15	0,60	0,64	0,57	0,34	0,31	0,91	0,86
май 2023	0,31	0,13	0,95	1,56	0,91	0,41	0,39	0,59	0,56
апрель 2023	0,34	0,30	1,29	1,98	1,37	0,40	0,39	0,99	0,96
март 2023	0,28	0,32	1,14	1,05	1,56	0,66	0,63	1,40	1,36
февраль 2023	0,28	0,30	0,36	0,58	1,35	0,59	0,57	1,34	1,30
январь 2023	0,26	0,04	0,14	0,51	0,35	0,62	0,56	1,03	1,01
декабрь 2022	0,39	0,04	0,27	0,94	0,73	0,62	0,51	0,21	0,19
ноябрь 2022	0,61	0,26	0,89	0,63	0,99	0,72	0,57	0,20	0,20

О к о н ч а н и е т а б л и ц ы 6

Прогноз на	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Группа моделей Г (ADL-MIDAS)		Группа моделей Д (ADL-MIDAS)	
						схема EW	схема MSFE	схема EW	схема MSFE
октябрь 2022	0,95	0,59	1,31	0,97	1,74	0,81	0,68	0,73	0,72
сентябрь 2022	1,30	1,68	0,59	2,74	2,76	0,82	0,64	0,72	0,72
Среднее RMSE	0,44	0,45	0,76	1,11	1,10	0,55	0,48	0,87	0,83

Примечание. В качестве даты прогноза указана дата, на которую сделан прогноз (например, для строки «сентябрь 2023» указана величина ошибки вневыборочного прогноза, сделанного в июле 2023 года на 3 месяца вперед).

Источник: рассчитано авторами.

Т а б л и ц а 7

P-значения теста Диболда – Мариано для попарного сравнения статистического различия качества прогноза на 1 месяц вперед в моделях А–Д

T a b l e 7

Diebold-Mariano Test P-Values for Pairwise Comparison of Statistical Differences in Forecast Accuracy for the Next Month in Models A-E

Прогноз на 1 месяц вперед	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Модель Г (ADL-MIDAS, схема MSFE)	Модель Д (ADL-MIDAS, схема MSFE)
Бенчмарк (ARMA 1,0)	X	0,45	0,08	0,14	0,24	0,68	0,23
Бенчмарк (ARMAX 1,0)		X	0,12	0,18	0,40	0,53	0,42
Модель А (SVAR)			X	0,78	0,05	0,03	0,04
Модель Б (SVAR _{online})				X	0,16	0,07	0,12
Модель В (MFVAR)					X	0,07	0,50
Модель Г (ADL-MIDAS, схема MSFE)						X	0,05
Модель Д (ADL-MIDAS, схема MSFE)							X

Источник: рассчитано авторами.

Т а б л и ц а 8

P-значения теста Диболда – Мариано для попарного сравнения статистического различия качества прогноза на 3 месяца вперед в моделях А–Д

T a b l e 8

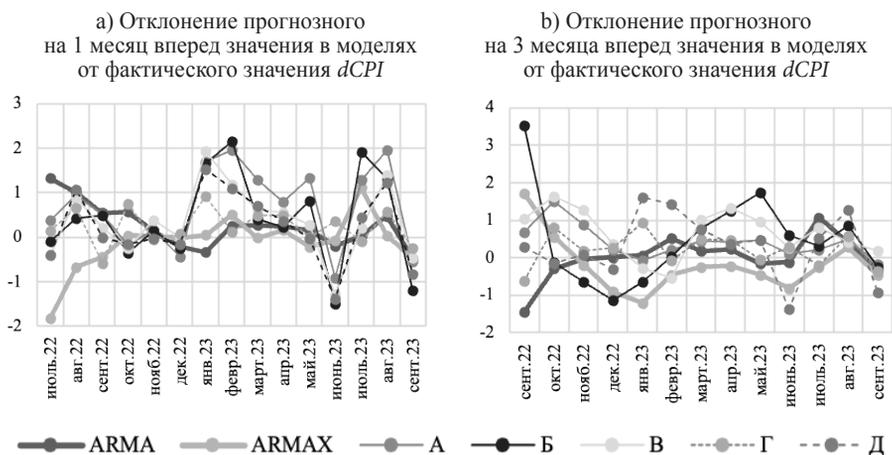
Diebold-Mariano Test P-Values for Pairwise Comparison of Statistical Differences in Forecast Accuracy for the Next Three Months in Models A-E

Прогноз на 3 месяца вперед	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Модель Г (ADL-MIDAS, схема MSFE)	Модель Д (ADL-MIDAS, схема MSFE)
Бенчмарк (ARMA 1,0)	X	0,21	0,83	0,13	0,11	0,68	0,21
Бенчмарк (ARMAX 1,0)		X	0,39	0,19	0,39	0,13	0,53
Модель А (SVAR)			X	0,15	0,01	0,56	0,36

Окончание таблицы 8

Прогноз на 3 месяца вперед	Бенчмарк (ARMA 1,0)	Бенчмарк (ARMAX 1,0)	Модель А (SVAR)	Модель Б (SVAR _{online})	Модель В (MFVAR)	Модель Г (ADL-MIDAS, схема MSFE)	Модель Д (ADL-MIDAS, схема MSFE)
Модель Б (SVAR _{online})				X	0,33	0,16	0,49
Модель В (MFVAR)					X	0,06	0,99
Модель Г (ADL-MIDAS, схема MSFE)						X	0,07
Модель Д (ADL-MIDAS, схема MSFE)							X

Источник: рассчитано авторами.



Источник: рассчитано авторами.

Рис. 4. Отклонение прогнозного значения на 1 месяц вперед (а) и 3 месяца вперед (б) от фактического значения *dCPI* в бенчмарк-моделях и моделях А-ДFig. 4. Deviation of Forecasts for the Next Month (a) and for the Next Three Months (b) From the Actual Value of *dCPI* in the Benchmark Models and Models A-E

Согласно результатам DM-теста, прогноз официальной инфляции в одномерных моделях в большинстве случаев качественно не отличается от прогноза, полученного в рассмотренных многомерных моделях инфляции. Включение данных об онлайн-ценах также не приводит к систематическому улучшению прогноза одномерных бенчмарк-моделей.

В классе многомерных моделей временных рядов прогноз на 1 месяц статистически значимо не улучшается при использовании данных об онлайн-ценах в агрегированном виде (согласно результатам DM-теста, качество прогноза в моделях А и Б одинаково), однако значимо улучшается при включении этих данных с более высокой частотой (качество прогноза в моделях В, Г и Д выше, чем в модели А). В случае прогноза на 3 месяца авторам не удалось обнаружить статистически значимого улучшения ка-

чества прогноза официальной инфляции при включении данных об онлайн-ценах (согласно результатам DM-теста, качество прогноза в моделях Б, В, Г и Д не выше, чем в модели А).

Заключение

Полученные результаты свидетельствуют, что эффект учета данных по онлайн-ценам в прогнозных моделях инфляции ограничен. Данные по онлайн-ценам могут быть приняты во внимание для целей улучшения краткосрочного прогноза инфляции в некоторых случаях, в частности в классе многомерных моделей временных рядов. Результаты также подчеркивают важность включения данных об онлайн-ценах именно в дезагрированном виде. Вместе с тем результаты указывают, что основной мотивацией включения данных об онлайн-ценах в модели инфляции являются задачи наукастинга, то есть прогнозирования ценовых тенденций ближайшего будущего. Ценность учета данных по онлайн-ценам снижается с расширением горизонта прогнозирования, но может повышаться в периоды резкого изменения ценовых тенденций, например в ситуации экономического кризиса. В результате в рамках наукастинга учет онлайн-данных в моделях инфляции может иметь значение при принятии оперативных решений денежно-кредитной политики.

Литература

1. Божечкова А. В., Евсеев А. С. Анализ жесткости цен в розничной онлайн-торговле Москвы // Экономическая политика. 2020. № 15(5). С. 32–59. DOI: 10.18288/1994-5124-2020-5-32-59.
2. Дьячкова Н. Ф. Подходы к построению высокочастотных ценовых индексов с использованием онлайн-данных // V Российский экономический конгресс «РЭК-2023». Т. III: тематическая конференция «Макроэкономика и экономический рост»: сборник тезисов докладов. Екатеринбург, 11-15 сентября 2023 г. Москва: Новая экономическая ассоциация, 2023. С. 27-30. https://www.econorus.org/pdf/Volume03_REC-2023.pdf.
3. Евсеев А. С., Латыпов Р. Р., Постолит Е. А., Синельникова-Мурылева Е. В. Технические и методологические проблемы сбора данных о ценах онлайн-ритейлеров // Экономическое развитие России. 2022. Т. 29. № 11. С. 36–45.
4. Исаков А., Латыпов Р., Репин А., Постолит Е., Евсеев А., Синельникова-Мурылева Е. Твердые цифры: открытые микроданные о потребительских ценах // Деньги и кредит. 2021. № 80(1). С. 104–119. DOI:10.31477/rjmf.202101.104.
5. Перевышин Ю. Н. Краткосрочное прогнозирование инфляции в российской экономике // Экономическая политика. 2022. Т. 17. № 5. С. 8–25.
6. Alper C., Fendoglu S., Saltoglu B. MIDAS Volatility Forecast Performance Under Market Stress: Evidence From Emerging Stock Markets // Economics Letters. 2012. No 117(2). P. 528–532. DOI:10.1016/j.econlet.2012.05.037.
7. Aparicio D., Bertolotto M. Forecasting Inflation With Online Prices // International Journal of Forecasting. 2020. No 36(2). P. 232–247. DOI:10.1016/j.ijforecast.2019.04.018.
8. Banbura M., Giannone D., Reichlin L. Nowcasting. ECB. Working Paper No 1275. 2010.
9. Breitung J., Roling C. Forecasting Inflation Rates Using Daily Data: A Nonparametric MIDAS Approach // Journal of Forecasting. 2015. No 34. P. 588–603. DOI:10.1002/for.2361.

10. Cavallo A. Are Online and Offline Prices Similar? Evidence From Large Multi-Channel Retailers// *American Economic Review*. 2017. No 107(1). P. 283–303. DOI: 10.1257/aer.20160542.
11. Cavallo A., Rigobon R. The Billion Price Project: Using Online Prices for Measurement and Research// *Journal of Economic Perspectives*. 2016. No 30(2). P. 151–178. DOI: 10.1257/jep.30.2.151.
12. Gabrielyan D. Forecasting Inflation Using the Phillips Curve in Inflation Targeting Countries// *International Review of Applied Economics*. 2019. No 33(5). P. 601–623. DOI:10.1080/02692171.2018.1516740.
13. Ghysels E. Macroeconomics and the Reality of Mixed Frequency Data// *Journal of Econometrics*. 2016. No 193. P. 294–314. DOI: 10.1016/j.jeconom.2016.04.008.
14. Ghysels E., Kvedaras V., Zemlys V. Mixed Frequency Data Sampling Regression Models: The R Package midasr// *Journal of Statistical Software*. 2016. No 72(4). P. 1–35. DOI: 10.18637/jss.v072.i04.
15. Ghysels E., Sinko A., Valkanov R. MIDAS Regressions: Further Results and New Directions// *Econometric Reviews*. 2007. No 26(1). P. 53–90. DOI: 10.1080/07474930600972467.
16. Kuzin V., Marcellino M., Schumacher C. MIDAS vs. Mixed-Frequency VAR: Nowcasting GDP in the Euro Area// *International Journal of Forecasting*. 2011. No 27(2). P. 529–542. DOI: 10.1016/j.ijforecast.2010.02.006.
17. Kvedaras V., Zemlys V. Testing the Functional Constraints on Parameters in Regressions With Variables of Different Frequency// *Economics Letters*. 2012. No 116(2). P. 250–254. DOI:10.1016/j.econlet.2012.03.009.
18. Monteforte L., Moretti G. Real-Time Forecasts of Inflation: The Role of Financial Variables// *Journal of Forecasting*. 2013. No 32. P. 51–61.
19. Ögünç F., Akdoğan K., Başer S., Chadwick M., Ertuğ D., Hülagü T., Kösem S., Özmen M., Tekath N. Short-Term Inflation Forecasting Models for Turkey and Forecast Combination Analysis// *Economic Modelling*. 2013. No 33. P. 312–325.
20. Schorfheide F., Song D. Real-Time Forecasting With a Mixed-Frequency VAR. NBER Working Paper No w19712. 2013. DOI: 10.3386/w19712.

References

1. Bozhechkova A.V., Evseev A.S. Analiz zhestkosti tsen v roznichnoy onlayn-torgovle Moskvy [Price Rigidity Analysis: Evidence From the E-Commerce Market]. *Ekonomicheskaya Politika [Economic Policy]*, 2020, no. 15(5), pp. 32-59. DOI: 10.18288/1994-5124-2020-5-32-59. (In Russ.)
2. Dyachkova N.F. Podkhody k postroeniyu vysokochastotnykh tsenovykh indeksov s ispol'zovaniem onlayn-dannykh [Approaches to Constructing High Frequency Price Indices Using Online Data]. In: *Rossiyskiy ekonomicheskiy kongress "REK-2023". Vol. III: Tematicheskaya konferentsiya "Makroekonomika i ekonomicheskiy rost": sbornik tezisev dokladov [Macroeconomics and Economic Growth Thematic Session at the Fifth Russian Economic Congress (REC-2023), Collection of Abstracts]*, Yekaterinburg, September 11-15. Moscow, New Economic Association, 2023, pp. 27-30. https://www.econorus.org/pdf/Volume03_REC-2023.pdf. (In Russ.)
3. Evseev A.S., Latypov R.R., Postolit E.A., Sinelnikova-Muryleva E.V. Tekhnicheskie i metodologicheskie problemy sbora dannykh o tsenakh onlayn-reteylerov [Technical and Methodological Challenges in Collecting Price Data From Online Retailers]. *Ekonomicheskoe razvitiye Rossii [Russian Economic Development]*, 2022, vol. 29, no. 11, pp. 36-45. (In Russ.)
4. Isakov A., Latypov R., Repin A., Postolit E., Evseev A., Sinelnikova-Muryleva E. Tverdye tsifry: otkrytye mikrodannye o potrebitel'skikh tsenakh [Hard Numbers: Open Consumer Price Database]. *Den'gi i kredit [Russian Journal of Money and Finance]*, 2021, no. 80(1), pp. 104-119. DOI: 10.31477/rjmf.202101.104. (In Russ.)
5. Perevyshin Yu. N. Kratkosrochnoe prognozirovaniye inflyatsii v rossiyskoy ekonomike [Short-Term Inflation Forecasting in the Russian Economy]. *Ekonomicheskaya Politika [Economic Policy]*, 2022, no. 5, pp. 8-25. (In Russ.)

6. Alper C., Fendoglu S., Saltoglu B. MIDAS Volatility Forecast Performance Under Market Stress: Evidence From Emerging Stock Markets. *Economics Letters*, 2012, no. 117(2), pp. 528-532. DOI:10.1016/j.econlet.2012.05.037.
7. Aparicio D., Bertolotto M. Forecasting Inflation With Online Prices. *International Journal of Forecasting*, 2020, no. 36(2), pp. 232-247. DOI:10.1016/j.ijforecast.2019.04.018.
8. Banbura M., Giannone D., Reichlin L. Nowcasting. *ECB*, Working Paper no. 1275, 2010.
9. Breitung J., Roling C. Forecasting Inflation Rates Using Daily Data: A Nonparametric MIDAS Approach. *Journal of Forecasting*, 2015, no. 34, pp. 588-603. DOI:10.1002/for.2361.
10. Cavallo A. Are Online and Offline Prices Similar? Evidence From Large Multi-Channel Retailers. *American Economic Review*, 2017, no. 107(1), pp. 283-303. DOI: 10.1257/aer.20160542.
11. Cavallo A., Rigobon R. The Billion Price Project: Using Online Prices for Measurement and Research. *Journal of Economic Perspectives*, 2016, no. 30(2), pp. 151-178. DOI: 10.1257/jep.30.2.151.
12. Gabrielyan D. Forecasting Inflation Using the Phillips Curve in Inflation Targeting Countries. *International Review of Applied Economics*, 2019, no. 33(5), pp. 601-623. DOI:10.1080/02692171.2018.1516740.
13. Ghysels E. Macroeconomics and the Reality of Mixed Frequency Data. *Journal of Econometrics*, 2016, no. 193, pp. 294-314. DOI: 10.1016/j.jeconom.2016.04.008
14. Ghysels E., Kvedaras V., Zemlys V. Mixed Frequency Data Sampling Regression Models: The R Package midasr. *Journal of Statistical Software*, 2016, no. 72(4), pp. 1-35. DOI: 10.18637/jss.v072.i04.
15. Ghysels E., Sinko A., Valkanov R. MIDAS Regressions: Further Results and New Directions. *Econometric Reviews*, 2007, no. 26(1), pp. 53-90. DOI: 10.1080/07474930600972467.
16. Kuzin V., Marcellino M., Schumacher C. MIDAS vs. Mixed-Frequency VAR: Nowcasting GDP in the Euro Area. *International Journal of Forecasting*, 2011, no. 27(2), pp. 529-542. DOI: 10.1016/j.ijforecast.2010.02.006.
17. Kvedaras V., Zemlys V. Testing the Functional Constraints on Parameters in Regressions With Variables of Different Frequency. *Economics Letters*, 2012, no. 116(2), pp. 250-254. DOI:10.1016/j.econlet.2012.03.009.
18. Monteforte L., Moretti G. Real-Time Forecasts of Inflation: The Role of Financial Variables. *Journal of Forecasting*, 2013, no. 32, pp. 51-61.
19. Ögünc F., Akdoğan K., Başer S., Chadwick M., Ertuğ D., Hülagu T., Kösem S., Özmen M., Tekatlı N. Short-Term Inflation Forecasting Models for Turkey and Forecast Combination Analysis. *Economic Modelling*, 2013, no. 33, pp. 312-325.
20. Schorfheide F., Song D. Real-Time Forecasting With a Mixed-Frequency VAR. *NBER*, Working Paper no. w19712, 2013. DOI: 10.3386/w19712.