



Munich Personal RePEc Archive

Nowcasting the growth rates of the export and import by commodity groups

Maiorova, Ksenia and Fokin, Nikita

RANEPA

June 2020

Online at <https://mpra.ub.uni-muenchen.de/109557/>
MPRA Paper No. 109557, posted 14 Sep 2021 20:51 UTC

Наукастинг темпов роста стоимостных объемов экспорта и импорта по товарным группам

Информация об авторах

Майорова Ксения Николаевна – младший научный сотрудник, лаборатория математического моделирования экономических процессов РАНХиГС при Президенте РФ (117517, Российская Федерация, Москва, просп. Вернадского, д. 82; e-mail: mayorovak99@gmail.com; контактный телефон: +79778689664)

Фокин Никита Денисович – научный сотрудник, лаборатория математического моделирования экономических процессов РАНХиГС при Президенте РФ (117517, Российская Федерация, г. Москва, просп. Вернадского, д. 82; e-mail: fokinikita@gmail.com; контактный телефон: +79258669652)

Аннотация

В работе рассматривается ряд моделей машинного обучения и эконометрики, а именно: Elastic Net, Random Forest, XGBoost и SSVS применительно к наукастингу большого набора данных долларовых стоимостных объемов российского экспорта и импорта по товарным группам. Мы используем лаги объемов товарных групп экспорта и импорта, биржевые цены на некоторые импортируемые и экспортируемые товары и другие переменные, за счет чего проблема проклятия размерности встает достаточно остро. Используемые нами модели достаточно популярны и хорошо себя зарекомендовали при прогнозировании в условиях наличия проклятия размерности, когда количество параметров модели превышает число наблюдений. Наиболее качественной моделью оказывается взвешенная модель методов машинного обучения, которая превосходит базовую модель ARIMA в наукастинге объемов как экспорта, так и импорта. В случае самых крупных товарных групп зачастую удается получить более качественный наукаст относительно модели ARIMA, согласно тесту Диболда-Мариано. Также полученные наукасты оказываются достаточно близки к историческим прогнозам Банка России, будучи построенными в сопоставимых условиях.

Ключевые слова: наукастинг; внешняя торговля; проклятие размерности; машинное обучение; российская экономика.

Коды JEL: C52, C53, C55, F17

Nowcasting the growth rates of the export and import by commodity groups

Information about the Authors

Ksenia Maiorova – Junior research fellow, RANEPa (82, Vernadskogo pr., 117517, Moscow, Russian Federation; e-mail: mayorovak99@gmail.com)

Nikita Fokin – Research fellow, RANEPa (82, Vernadskogo pr., 117517, Moscow, Russian Federation; e-mail: fokinikita@gmail.com)

Abstract

In this paper we consider a set of machine learning and econometrics models, namely: Elastic Net, Random Forest, XGBoost and SSVS as applied to nowcasting a large dataset of USD volumes of Russian exports and imports by commodity group. We use lags of the volumes of export and import commodity groups, prices for some imported and exported goods and other variables, due to which the curse of dimensionality becomes quite acute. The models we use are very popular and have proven themselves well in forecasting in the presence of the curse of dimensionality, when the number of model parameters exceeds the number of observations. The best model is the weighted model of machine learning methods, which outperforms the ARIMA benchmark model in nowcasting the volume of both exports and imports. In the case of the largest commodities groups, we often get a significantly more accurate nowcasts than ARIMA model, according to the Diebold-Mariano test. In addition, nowcasts turns out to be quite close to the historical forecasts of the Bank of Russia, being constructed in similar conditions.

Key words: nowcasting; foreign trade; curse of dimensionality; machine learning; Russian economy

JEL Codes: C52, C53, C55, F17

1. Введение

В данной работе мы используем большой набор поквартальных данных Федеральной таможенной службы о стоимостных (то есть номинальных) объемах экспорта и импорта по товарным группам согласно классификации товарной номенклатуры внешнеэкономической деятельности (ТН ВЭД). Мы прогнозируем темпы роста экспорта и импорта по двузначным товарным группам, используя в качестве предикторов лаги темпов роста стоимостных объемов, реальный эффективный курс рубля, цены на некоторые экспортируемые из России и импортируемые в Россию товары, которые торгуются на международных биржах – нефть, газ, различные металлы –, а также другие переменные.

В этой работе мы преследуем две цели. Первая цель – тестирование качества наукастинга¹ рассматриваемых моделей на используемом наборе показателей экспорта и импорта по товарным группам. Вторая – сравнение качества наукаста основных показателей (совокупного экспорта и совокупного импорта), построенного моделями машинного обучения, и квартальных наукастов Банка России.

Прогнозирование динамики экспорта и импорта является достаточно важной актуальной задачей. Качественные прогнозы объемов экспорта и импорта позволят государству лучше планировать внешнеторговую деятельность, проводить более правильную политику на валютном рынке, например, корректировать параметры бюджетного правила, проводить эффективную политику импортозамещения и таможенно-тарифную политику для поддержания конкурентоспособности отечественных производителей. Стоит также добавить, что экспорт представляет собой существенную часть валового внутреннего продукта России (в период 1995–2020 гг. – порядка 30% как в постоянных, так и в текущих ценах), поэтому качественные прогнозы объемов экспорта полезны и при прогнозировании ВВП.

В зарубежной и отечественной литературе представлено большое число работ по моделированию динамики физических объемов экспорта и импорта. В случае импорта классической задачей считается оценивание функции спроса на импорт, тогда как предложение импорта предполагается бесконечным. Например, Clarida (1996) и Senhadji (1998) выводят из теоретических моделей долгосрочные соотношения, согласно которым агрегированный импорт коинтегрирован с некоторым показателем агрегированных расходов и показателем относительных цен импортных товаров к отечественным. Оценивание функции спроса на экспорт является более сложной задачей, так как спрос предъявляет сразу множество стран. Senhadji (1999) предлагает модель, согласно которой физический объем экспорта зависит от относительной цены экспортного

¹ Наукастинг – краткосрочный прогноз экономического индикатора в текущем периоде, для которого еще недоступна официальная статистика.

товара к ценам на товары стран-конкурентов и суммарного выпуска, за исключением экспорта стран – торговых партнеров. Похожие подходы моделирования экспорта и импорта на российских данных применяет, например, Емельянов (2007).

При этом оценка функций спроса на импорт и экспорт для каждой товарной группы является слишком объемной задачей, которую зачастую нельзя решить из-за отсутствия данных. В России объемы импорта в долларах США и в постоянных ценах имеют почти идентичную динамику, что означает, что для спецификации функции спроса на импорт и его прогнозирования можно использовать в качестве регрессоров те же переменные, что и в теоретической функции спроса на импорт в постоянных ценах: показатель внутреннего дохода и реальный обменный курс. Долларовый экспорт имеет динамику, отличную от динамики экспорта в постоянных ценах, спецификация функции спроса из теоретических соображений для данного показателя не очевидна.

Кроме того, оценка функции спроса (как на экспорт, так и на импорт) является задачей несмещенной оценки параметров эластичности по доходу и относительным ценам. Функцию спроса можно рассматривать как коинтеграционное соотношение. В случае наличия коинтеграции строится модель коррекции ошибок (Error Correction Model, ECM), в ином случае – векторная авторегрессия (Vector Autoregression, VAR). В обоих случаях модель специфицируется с использованием лишь прошлых значений рассмотренных показателей. Такая модель будет прогнозировать заведомо хуже, чем модель, в которой участвуют предикторы в текущий момент времени, известные на момент построения прогноза. Однако включение переменных, определенных в текущий момент времени, может повлечь за собой эндогенность и требует оценки с использованием инструментов для несмещенной оценки параметров. Как показывают Полбин и Фокин (2020) в работе, посвященной оценке функции спроса на российский импорт, несмещенная оценка параметров не является необходимой для качественного прогноза. Авторы заключают, что наиболее качественный наугад импорта получается при использовании модели с включением текущего значения реального обменного курса и оценкой модели методом наименьших квадратов (МНК). Модель, оцененная с использованием обобщенного метода моментов (Generalised Method of Moments, GMM), и модель с включением только запаздывающих значений дают менее качественный прогноз.

На наш взгляд, разработке подходов непосредственно к прогнозированию экспорта и импорта в России в литературе уделено недостаточно внимания; доступны лишь периодически выходящие обзоры текущей экономической ситуации в России и макроэкономические прогнозы Банка России, Министерства экономического развития РФ и Института Гайдара², основанные на

² См., например, Банк России (2020), Министерство экономического развития Российской Федерации (2020), «Мониторинг экономической ситуации в России: тенденции и вызовы социально-экономического развития» (2020).

различных структурных моделях, а также стандартных интегрированных моделях авторегрессии – скользящего среднего (Autoregressive Integrated Moving Average, ARIMA) и VAR. В данной работе мы предлагаем модели для прогнозирования не только агрегированных рядов стоимостных объемов экспорта и импорта, но и объемов внешней торговли по различным товарным группам. К примеру, Банк России в оценках платежного баланса в аналитическом представлении помимо данных по агрегированному экспорту предоставляет также данные по экспорту сырой нефти, нефтепродуктов, природного газа и сжиженного природного газа. Кроме того, мы рассматриваем целый комплекс альтернативных методов, ранее не применявшихся, насколько нам известно, к отечественным показателям внешней торговли, а также иной подход к проблеме выбора потенциально важных предикторов для рассматриваемых переменных.

Для решения поставленной задачи мы используем модели машинного обучения и байесовской эконометрики, устойчивые к проклятию размерности, а именно: эластичные сети (Elastic Net, EN), случайный лес (Random Forest, RF), алгоритм градиентного бустинга (XGBoost, XGB), выбор регрессоров стохастическим поиском (Stochastic Search Variable Selection, SSVS), комбинированную модель авторегрессии (Autoregression, AR) первого порядка с LASSO (Least Absolute Shrinkage And Selection Operator) – AR-LASSO, а также метод усреднения прогнозов, полученных методами машинного обучения (EN, RF, XGB) с весами, обратно пропорциональными ошибкам на валидационной выборке.

Набор используемых моделей мы формировали на основе двух принципов. Во-первых, модель должна быть устойчива к проблеме проклятия размерности, то есть способна тем или иным способом выбирать из большого набора те регрессоры, которые имеют наибольшую объясняющую силу. Во-вторых, модель должна была достаточно хорошо себя зарекомендовать при сравнении с классическими методами, проведенном в более ранних исследованиях, посвященных прогнозированию различных макропоказателей.

Например, Jokubaitis et al. (2021) используют модель LASSO и ее модификации с целью получить разреженную матрицу из всего набора данных для прогнозирования квартального ВВП и его компонент в США и в некоторых странах еврозоны. В их работе методы LASSO в большинстве случаев дают более точные результаты, чем эталонная модель ARIMA.

Для извлечения и систематизации полезной информации из большого числа предикторов подходит также динамическая факторная модель (Dynamic Factor Model, DFM) и ее модификации. Li and Chen (2014) сравнивают прогностические способности LASSO и EN с DFM для двадцати макроэкономических переменных, таких как инфляция, уровень занятости, показатели денежной массы, обменный курс и др. Для большинства исследуемых переменных модели LASSO

превосходят DFM по качеству прогнозов, а сочетание прогнозов этих моделей помогает еще больше уменьшить среднеквадратичную ошибку прогноза (Mean Square Forecast Error, MSFE).

Ансамблевые методы – случайный лес и бустинг – достаточно хорошо проявили себя в исследовании Gareev (2020), посвященном прогнозированию темпа роста квартального валового накопления основного капитала в России, обойдя по качеству прогноза не только такие простые эталонные модели, как модель авторегрессии и модель случайного блуждания, но и методы регуляризации – LASSO с модификациями, Ridge, EN и байесовский метод Spike and Slab. Схожие результаты получил Baybuza (2018), который применяет методы машинного обучения для прогнозирования российской инфляции, показывая, что случайный лес и модель бустинга предсказывают инфляцию не хуже, чем более традиционные модели.

Идея применить SSVS на наших данных появилась из статьи Коор (2013), автор которой тестирует байесовские методы с различными априорными распределениями для VAR нескольких размеров и сравнивает прогнозы ВВП, индексу потребительских цен и процентной ставки (ставки по федеральным фондам). Коор (2013) показывает, что байесовские VAR прогнозируют лучше, чем факторные методы, для каждой зависимой переменной на всех горизонтах.

Рассматриваемые нами данные ФТС выходят с лагом относительно статистики по сырьевым ценам, реальному эффективному курсу и другим рассматриваемым показателям. Поэтому на основе рассматриваемых моделей можно построить наукаст в реальном времени, то есть оценивать динамику показателя в уже наступившем квартале, в условиях, когда данные в правой части уравнений известны, но данные по прогнозируемой переменной еще не опубликованы. При выборе лучшей в плане прогнозной силы модели мы тестируем качество псевдовневыборочных наукастов. В заключительной части работы мы сравниваем качество наукастов используемых нами моделей и наукастов Банка России за период с III квартала 2019 г. по IV квартал 2020 г.

2. Используемые модели

2.1. Эластичная сеть (EN)

Для прогнозирования в условиях проклятия размерности, пожалуй, одним из самых популярных решений является построение модели с регуляризацией. Объединяющей две базовые регуляризации Lasso и Ridge (Tibshirani, 1996), является модель EN (Zou, 2005). В данной модели используется функционал МНК для линейной регрессии с добавлением дополнительного члена, штрафующего коэффициенты за их избыточную величину.

$$\operatorname{argmin}_{\beta} \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda (\alpha \sum_{j=1}^p |\beta_j| + (1-\alpha) \sum_{j=1}^p \beta_j^2), \quad (1)$$

где y_i – объясняемая переменная, $i = 1, \dots, n$; x_{ij} – j -ая объясняющая переменная $j = 1, \dots, p$; β_j – коэффициент перед j -ой объясняющей переменной; λ – гиперпараметр, отвечающий за силу штрафа; α – гиперпараметр, отвечающий за вес L1- и L2-регуляризаций.

Параметр λ отвечает за то, с какой силой коэффициенты будут стягиваться к нулю. При $\lambda = 0$, полученные оценки будут совпадать с оценками МНК, если их возможно получить. А при $\lambda \rightarrow \infty$ все коэффициенты будут приближаться к нулю. Таким образом, с увеличением λ снижается сложность модели.

В работе Zou (2005) на симуляциях наблюдается лучшая эффективность прогнозирования Ridge по сравнению с LASSO в случаях, когда $n > p$ и существуют высокие корреляции между предикторами. Также автор показывает, что L1-регуляризация на параметры может приводить к полному обнулению коэффициентов при некоторых переменных, объясняющая сила которых несущественна. То есть на выходе получается разреженный вектор оценок коэффициентов для задачи выбора релевантных регрессоров.

При построении EN необходимой процедурой является нормирование объясняющих переменных. Так как коэффициенты штрафуются за их абсолютную величину с одинаковым весом λ , необходимо предотвратить ситуацию, когда переменные с отличающимися дисперсиями будут штрафовать с одинаковой силой.

2.2 Случайный лес (RF) и XGBoost

В основе RF лежит алгоритм решающего дерева. На каждом шаге определяется оптимальное разбиение всей выборки R из N наблюдений по какому-либо признаку x_j и пороговому значению t для этого признака, задающих условие для разбиения вершины: $R_l(j, t) = \{x | x_j < t\}$, $R_r(j, t) = \{x | x_j \geq t\}$, согласно функционалу качества $Q(R, j, t)$. Наблюдения, для которых условие выполнено, попадают в левую подвыборку R_l (из N_L наблюдений), остальные в правую R_r (из N_R наблюдений). Функционал качества для данного алгоритма записывается следующим образом:

$$Q(R, j, t) = H(R) - \frac{N_L}{N} H(R_l) - \frac{N_R}{N} H(R_r), \quad (2)$$

где $H(R)$ – некоторая мера однородности выборки.

Для задач регрессии информативность вершины измеряется дисперсией значений целевой переменной в ней: чем меньше они отличаются друг от друга, тем большей информацией мы обладаем.

Ставится задача максимизировать $Q(R, j, t)$, минимизируя $H(R_l)$ и $H(R_r)$, то есть на каждом шаге ищется условие, разбивающее выборку R так, чтобы при разделении разбросы значений объясняемой переменной в левой и правой подвыборках были бы минимальными. В самых нижних вершинах дерева (листьях), по которым алгоритм уже не делает разбиение, находится ответ

алгоритма. Для задач регрессии решение – это среднее значение целевой переменной по наблюдениям, попавшим в данные вершины.

Если не указывать критерий остановки, процесс разбиения будет продолжаться, пока дерево не достигнет максимальной глубины. Дерево будет идеально работать на конкретной выборке, но показывать плохой результат на новых данных, то есть будет переобучено. Поэтому были придуманы ансамблевые методы – техника обучения, когда используется не одна модель, а их совокупность. Случайный лес является ансамблем над решающим деревом: для каждого из деревьев генерируется подвыборка из всех исходных данных, а число признаков для обучения модели выбирается случайным образом из всего множества (Breiman, 2001). Итоговый прогноз для задачи регрессии – это усредненные прогнозы каждого из решающих деревьев.

В случайном лесе деревья обучаются независимо друг от друга. С целью построения модели, учитывающей результаты предыдущих итераций, был предложен градиентный бустинг, а затем его усовершенствование, XGBoost (Chen, 2016).

Рассмотрим оптимизационную задачу бустинга над деревьями решений, на основе которой выбирается решающее дерево на шаге t :

$$\mathcal{L}^{(t)} = \underset{f_t(x_i)}{\operatorname{argmin}} \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \Omega(f_t) \quad (3)$$

где f_t – функция (в нашем случае решающее дерево), оптимальное значение которой мы ищем на шаге t ; x_i – набор признаков i -го наблюдения обучающей выборки; y_i – фактическое значение i -го наблюдения обучающей выборки; $\hat{y}_i^{(t)}$ – сумма предсказаний первых t деревьев; l – функция потерь; $\Omega(f_t)$ – регуляризационная функция, штрафующая дерево за излишнюю сложность и препятствующая его переобучению.

В качестве функции регуляризации можно рассматривать различные спецификации. Универсальной является следующая:

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2, \quad (4)$$

где T – число листьев в дереве, w – значения прогнозов в листьях, λ и γ – параметры регуляризации. То есть включение данной функции в целевой функционал препятствует излишней сложности дерева, а также штрафует за величину прогнозов в листьях, отражающую вес прогноза дерева в ансамбле.

В бустинге для обучения модели используется аддитивная стратегия. Прогноз каждого последующего шага учитывает ответ алгоритма на предыдущем шаге:

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (5)$$

Запишем оптимизационную задачу, используя MSE в качестве функции потерь l и подставив $\hat{y}_i^{(t)}$:

$$\mathcal{L}^{(t)} = \underset{f_t(x_i)}{\operatorname{argmin}} \sum_{i=1}^n (f_t(x_i) - (y_i - \hat{y}_i^{(t-1)}))^2 + \Omega(f_t) \quad (6)$$

Итак, на шаге t ставится задача найти такое дерево $f_t(x_i)$, которое минимизировало бы функционал $\mathcal{L}^{(t)}$, учитывающий остатки, то есть отклонение полученного на основе предыдущих деревьев предсказанного значения от реального. Каждая следующая модель будет строиться так, чтобы максимально корректировать ошибки ранее построенных моделей.

2.3 Выбор регрессоров стохастическим поиском (SSVS)

SSVS – байесовский метод с иерархичным априорным распределением, дающий на выходе, аналогично LASSO, разреженный вектор имеющих наибольшую объясняющую силу регрессоров из большого набора (George and McCulloch, 1993), что является особенно важным фактором применительно к нашей задаче выбора переменных в условиях проклятия размерности. Рассматривается линейная модель, где коэффициент при j -ом регрессоре β_j априорно имеет взвешенное распределение из двух нормальных распределений с нулевыми средними, но с сильно отличными дисперсиями. Одно из распределений имеет малую дисперсию с большой плотностью в 0 (коэффициент скорее всего окажется равным 0 и данный регрессор может быть исключен из модели), а другое имеет большую дисперсию (коэффициент с высокой вероятностью будет отличен от 0, следовательно, переменная должна остаться в модели).

$$P(\beta_j | \gamma_j) = (1 - \gamma_j) N(0, r_{0j}^2) + \gamma_j N(0, r_{1j}^2), \quad (7)$$

где γ_j – это случайная величина, имеющая распределение Бернулли:

$$\begin{aligned} P(\gamma_j = 1) &= q_j, \\ P(\gamma_j = 0) &= 1 - q_j \end{aligned} \quad (8)$$

В данной работе q_j выбрано равным 0,5 для каждого j , то есть подразумевается, что каждый коэффициент априорно может быть как включен, так и исключен из модели с равной вероятностью. Следуя Коор (2013), в качестве дисперсий r_{0j}^2 и r_{1j}^2 мы берем дисперсии коэффициента парной регрессии объясняемой переменной на j -й регрессор, умноженные на 0,1 и на 10 соответственно.

2.4 Комбинированные модели

Помимо базовой модели ARIMA, порядок которой выбирается на основе байесовского информационного критерия (Bayesian Information Criterion, BIC), мы строим модель AR-LASSO,

следуя подходу, описанному Baybuza (2018). На первом этапе с помощью LASSO мы отбираем экзогенные факторы, а затем в пространство объясняющих переменных добавляем первый лаг зависимой переменной. Таким образом получается комбинированная LASSO и AR(1)-модель.

Также для повышения точности наукаста мы применяем метод усреднения прогнозов, полученных методами машинного обучения EN, RF и XGB. В качестве веса модели используется отношение обратной среднеквадратической ошибки (Root Mean Squared Error, RMSE) наукастов данной модели на валидационной выборке к сумме обратных RMSE всех трех моделей. Далее наукасты отдельных моделей, умноженные на их веса, суммируются для получения наукаста взвешенной модели (Weighted Model, WM).

3. Описание данных и процедуры выбора гиперпараметров

3.1 Используемые данные

Для проведения исследования мы собрали большой набор данных ФТС о долларовых стоимостных объемах российского экспорта и импорта за период с I квартала 2005 г. по IV квартал 2020 г. по двузначным товарным группам в классификации ТН ВЭД. Всего в нашем распоряжении имеется статистика по 97 товарным группам, а также совокупному экспорту и импорту. Укрупненные группы товарных категорий приведены в Табл. 1³.

Таблица 1. Категории экспорта и импорта

Наименование укрупненных групп	коды ТН ВЭД
Совокупный экспорт и импорт	–
Продовольственные товары и сельскохозяйственное сырье (кроме текстильного)	01–24
Минеральные продукты; топливно-энергетические товары	25–27
Продукция химической промышленности, каучук	28–40
Кожевенное сырье, пушнина и изделия из них	41–43
Древесина и целлюлозно-бумажные изделия	44–49
Текстиль, текстильные изделия и обувь*	50–67
Драгоценные камни, драгоценные металлы и изделия из них	71
Металлы и изделия из них	72–83
Машины, оборудование и транспортные средства	84–90
Другие товары	68–70; 91–97

Примечание: экспортная товарная группа с кодом 50 (шелк) была исключена из рассмотрения из-за большого числа пропущенных значений на заданном интервале. Товарная группа с кодом 77 находится в резерве и не используется.

³ Более подробную разбивку по товарным группам см. на сайте ФТС: <http://stat.customs.ru/documents> (дата обращения: 21.07.2021)

В пространство предикторов включены первые лаги темпов роста объемов экспорта и импорта всех товарных групп, текущий и первые лаги темпов роста реального эффективного курса, индекса промышленного производства, текущие и первые лаги различных биржевых цен на товары, занимающие большую долю в совокупном экспорте и импорте (нефть, газ, бензин, древесину, пшеницу, цветные металлы, медь, алюминий, сталь, золото, зерно, органическую химическую продукцию, медицинское оборудование и расходные материалы, мясную и овощную продукцию и др.), а также опережающие индикаторы экономической активности, публикуемые ОЭСР: композитный опережающий индикатор (Composite Leading Indicator, CLI), индекс предпринимательской уверенности (Business Confidence Index, BCI) и индекс потребительской уверенности (Consumer Confidence Index, CCI) для России, США, Китая, ОЭСР, европейских стран-членов ОЭСР, G7 и еврозоны. Таким образом, все пространство объясняющих переменных для каждой зависимой переменной составляет 273 регрессора⁴ при 60 наблюдениях.

Ряды объемов экспорта и импорта, а также всех объясняющих переменных, за исключением индексов CLI, BCI, CCI (данные индексы представляют собой очищенные от долгосрочного тренда показатели), берутся в логразности квартал к аналогичному кварталу предыдущего года. Такая процедура позволяет не чистить ряды от сезонности, и прогнозировать исходный ряд. Как известно, чистка от сезонности подразумевает работу с некоторым искусственным временным рядом, а также на выборках длины T и длины $T + 1$ данная процедура может давать сильно различные значения очищенного ряда в точке T . Дополнительное описание переменных можно найти в Приложении (см. Табл. П1).

Благодаря особенностям выхода статистики мы можем строить наукаст темпов роста объемов. Текущие биржевые цены, реальный курс и индексы становятся доступны во вторую неделю месяца, следующего за отчетным, а квартальные бюллетени «Таможенная статистика внешней торговли Российской Федерации» ФТС выходят с лагом в два квартала – например, бюллетень ФТС за IV квартал 2020 г. был опубликован во II квартале 2021 г. Ориентировочно 10 числа каждого месяца ФТС публикует и более оперативные данные⁵, с лагом не два квартала, а два месяца – например, данные за апрель 2021 г. стали доступны в июне 2021 г., – но их недостатком как источника является отсутствие исторических данных (в соответствующем разделе на сайте ФТС доступны лишь три последних года). Поэтому мы выбрали для анализа первый из упомянутых источников – квартальные бюллетени ФТС, которые доступны, начиная с 2005 г., но выходят с большой задержкой. Таким образом, построенный наукаст опережает официальную статистику на один месяц.

⁴ Первые лаги совокупного экспорта и импорта, 95 товарных групп экспорта (без групп 50 и 77), 96 товарных групп импорта (без 77 группы), а также текущие и первые лаги 40 экзогенных предикторов.

⁵ См. <http://stat.customs.gov.ru/analysis> (дата обращения 21.07.2021)

3.2. Подбор гиперпараметров

Для ряда выбранных нами моделей встает вопрос о том, какие гиперпараметры являются оптимальными. На практике для определения наилучших значений гиперпараметров (в плане качества псевдовневыборочных прогнозов) часто используется кросс-валидация, при которой подбор параметра осуществляется на отложенной выборке.

В качестве алгоритма поиска и оптимизации гиперпараметров используется классический перебор по сетке. Так как наши данные являются временными рядами, мы проводим кросс-валидацию с расширяющимся окном, которая не требует перемешивания данных и не приводит к потере извлекаемой информации. Метод состоит в том, что вся выборка делится на три части. В данной работе, как и в Nicholson (2017), используются равные части, по 1/3 выборки. На первой части модель обучается с различными заданными значениями гиперпараметров. Далее каждая раннее обученная модель строит псевдореальный наукаст на одну точку вперед. Прогноз запоминается, а значение добавляется в обучающую выборку, после чего модели переоцениваются и строится прогноз на следующую точку, и так до исчерпания отложенной выборки. Получив векторы из прогнозов, построенных моделями с разными значениями гиперпараметров, мы сравниваем модели по качеству прогноза с помощью RMSE. Затем наилучшая модель обучается на первой и второй частях, и аналогично описанному ранее алгоритму строится псевдореальный наукаст на третьей части. Именно по результатам качества прогноза на последней части сравниваются между собой все построенные в данной работе модели.

В случае EN встает вопрос о том, какие α и λ являются оптимальными, с каким весом включать каждую из моделей и с какой силой штрафовать коэффициенты. При построении случайного леса важными гиперпараметрами для подбора являются минимальное число наблюдений в конечных вершинах (листах), максимальное число признаков, по которым ищется разбиение в каждой вершине и минимальное количество наблюдений, необходимое для разделения внутреннего листа. Что касается числа деревьев в каждом лесу, важным эмпирическим фактом является то, что случайный лес не склонен к переобучению, то есть при увеличении числа деревьев качество на отложенной выборке вначале растет, а затем приближается к асимптоте и перестает меняться. Так как приближение к асимптоте происходит с разной скоростью, в данной работе при построении случайного леса для каждой зависимой переменной мы взяли 1000 решающих деревьев.

В отличие от случайного леса, где деревья обучаются независимо и, вследствие этого начиная с определенного момента не наблюдается прироста в качестве, в XGB число деревьев является важным гиперпараметром, так как каждое последующее дерево подстраивается под уже имеющуюся композицию деревьев с учетом ошибок предыдущих итераций. Поэтому для XGB на отложенной выборке определяются такие параметры, как число решающих деревьев, максимальная

глубина каждого дерева, число признаков, на котором строится каждое дерево, а также значения коэффициентов регуляризации, отвечающие за силу штрафования сложности дерева⁶.

4. Сравнение прогнозной силы моделей

Мы сравниваем псевдовневыборочные наукасты, построенные подобранными для каждой товарной группы моделями, с бенчмарком ARIMA без экзогенных переменных, порядок которой выбирается на основе BIC, используя как метрику качества RMSE. Тестовая выборка включает период с I квартала 2015 г. по IV квартал 2020 г. Результаты сравнения (процент от общего числа категорий, где рассматриваемая модель оказывается лучше ARIMA) представлены в Табл. 2.

Таблица 2. Сравнение моделей с ARIMA по качеству прогноза

	Модель лучше ARIMA (в % случаев)						Хотя бы одна модель
	EN	RF	XGB	WM	SSVS	AR-Lasso	
Среди категорий экспорта	53%	52%	42%	69%	12%	31%	84%
Среди категорий импорта	41%	51%	35%	58%	5%	26%	70%
Среди всех категорий	47%	51%	38%	64%	8%	28%	76%

WM, EN и RF показывают себя лучше остальных в попарном сравнении с ARIMA. Данные модели точнее предсказывают объемы экспорта более чем в половине случаев. Кроме того, RF лучше предсказывает объемы импорта в 51% случаев, а WM – в 58%. Если рассматривать лучший результат всех шести моделей, качество прогнозов по моделям будет выше, чем у ARIMA, в 76% случаев среди всех категорий. Отметим, что ARIMA проявляет себя при прогнозировании объемов импортных категорий лучше, чем экспортных, причем зачастую эта модель показывает лучший результат для маленьких по объему товарных групп.

В Приложении (см. Табл. П3 и П4) приведены отношения RMSE всех моделей к RMSE ARIMA, а также результаты теста Диболда – Мариано (DM тест; см. Diebold and Mariano, 2002) при псевдовневыборочном наукасте объемов экспорта и импорта по десяти крупнейшим товарным

⁶ Множества, которые мы использовали для поиска оптимальных гиперпараметров для каждой модели, приведены в Приложении (см. Табл. П2).

группам, которые в среднем в рассматриваемом периоде покрывают 85% от совокупного экспорта и около 60% от совокупного импорта.

5. Сравнение с историческими прогнозами Банка России

В данном разделе мы сравниваем качество наукастов совокупного экспорта и совокупного импорта, построенного моделями машинного обучения, с квартальными наукастами Банка России за период с III квартала 2019 г. по IV квартал 2020 г.

Банк России регулярно публикует информационно-аналитические комментарии по платежному балансу России⁷, в которых присутствуют таблицы с фактическими значениями совокупного долларового экспорта и импорта, а также их оценка за текущий квартал. На последней странице комментария указывается дата отсечения данных. При построении наукаста на основе моделей машинного обучения мы используем ту же дату отсечения данных, что и в комментарии Банка России. Из методических пояснений к оценке платежного баланса следует, что Банк России использует при оценке оперативные месячные данные ФТС и динамику других показателей, то есть при построении наукаста на текущий квартал используются данные за два первых месяца данного квартала. В рассмотренных в нашей работе моделях такой подход нереализуем ввиду отсутствия месячных исторических данных ФТС (они доступны лишь за последние 3 года в любой момент времени). При этом Банк России сталкивается с проблемой регулярного пересмотра данных со стороны ФТС, а мы строим ретроспективный прогноз на уже пересмотренных данных. Несмотря на два эти фактора, в целом условия построения прогноза являются сопоставимыми.

Для сравнения мы отобрали по три модели для прогнозирования экспорта и импорта, показавшие наилучшее качество на валидационной выборке. Качество сравнивается на валидационной выборке, так как тестовая выборка содержит период сравнения (III 2019 г. – IV квартал 2020 г.). Результаты сравнения представлены на Рис. 1 и 2.

Рисунок 1. Фактические и прогнозные значения стоимостных объемов совокупного экспорта

⁷ См. Платежный баланс Российской Федерации, <https://cbr.ru/analytics/dkp/bal/> (дата обращения: 21.07.2021).

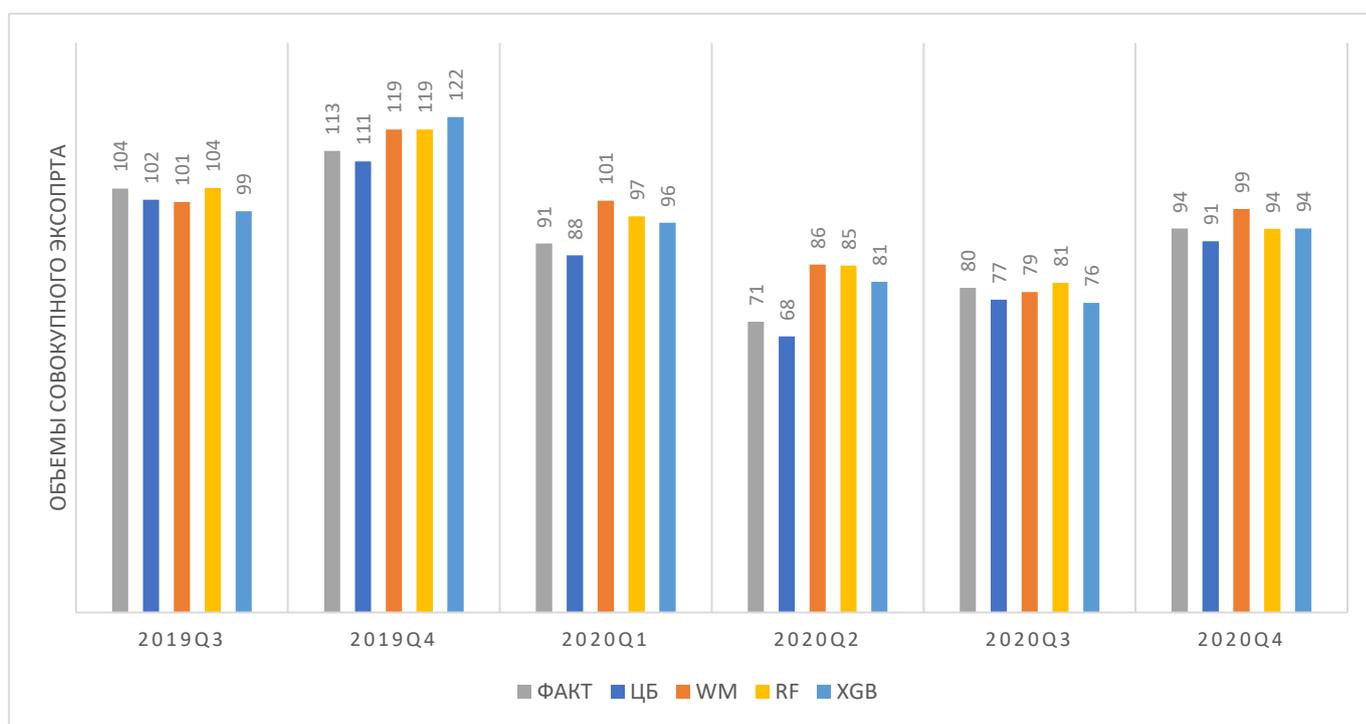
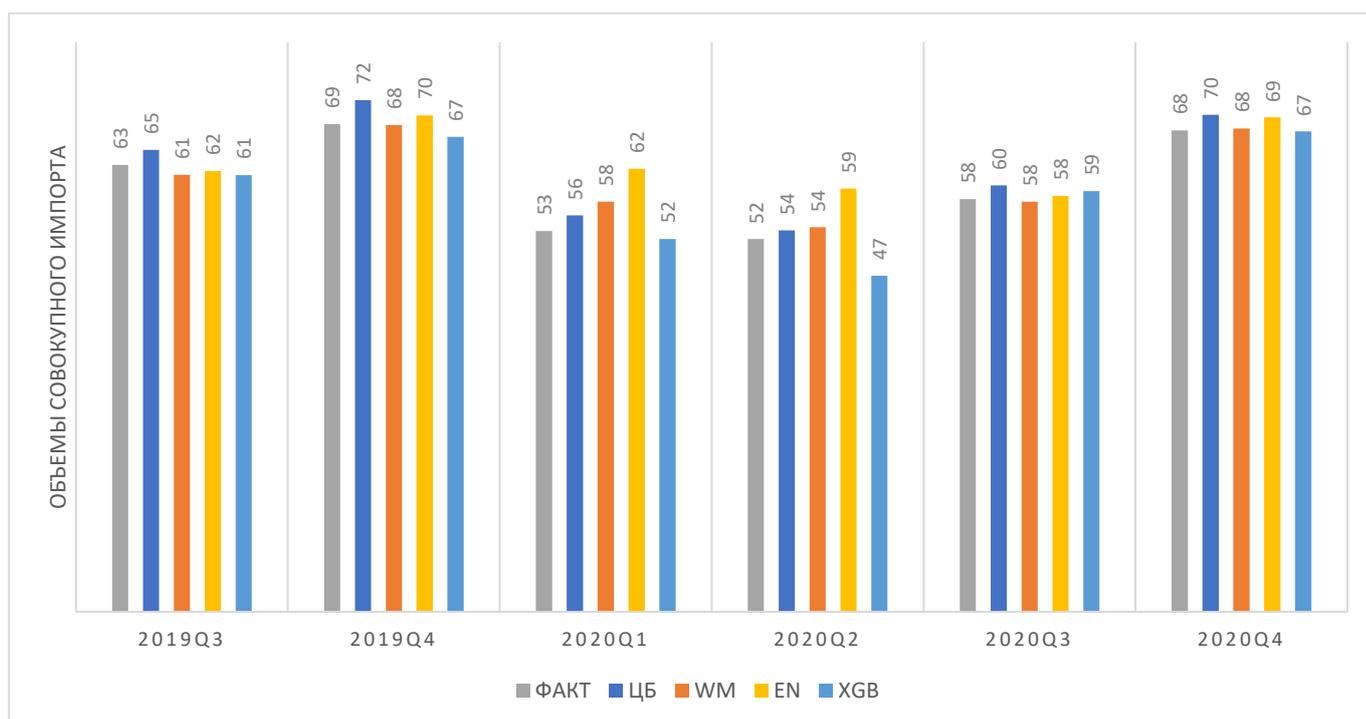


Рисунок 2. Фактические и прогнозные значения стоимостных объемов совокупного импорта



В Табл. 3 представлены результаты расчета различных метрик качества⁸ наукастов, построенных нашими моделями, и наукастов Банка России: RMSE, средняя абсолютная ошибка (Mean Absolute Error, MAE), средняя абсолютная процентная ошибка (Mean Absolute Percentage Error, MAPE), среднее абсолютное процентное отклонение (Percentage Mean Absolute Deviation,

⁸ Формулы расчета см. в Приложении, Табл. П5.

PMAD). Полу жирным выделены наилучшие результаты в строке для каждого показателя. Отметим, что при прогнозировании экспорта более качественным по всем метрикам оказался наукаст Банка России, тогда как для импорта по всем метрикам наилучшим оказался наукаст, построенный взвешенной моделью.

Таблица 3. Сравнение качества наукаста с использованием различных метрик

Метрика	Экспорт				Импорт			
	Банк России	WM	RF	XGB	Банк России	WM	EN	XGB
RMSE	7,3	19,4	16,3	15,34	5,6	4,7	11,5	5,8
MAE	17,8	49,3	27,3	32,4	13,1	8,0	20,1	10,7
MAPE	20,0%	45,4%	33,2%	36,6%	21,4%	14,3%	36,4%	19,0%
PMAD	3,2%	8,9%	4,9%	5,6%	3,6%	2,2%	5,6%	3,0%

Интересным является вопрос о том, какие предикторы являются наиболее важными для прогнозирования. Рассмотрим его на примере модели случайного леса, которая является лучшей по качеству после взвешенной модели. Так как случайный лес является совокупностью решающих деревьев, мы можем вычислить, какие предикторы были эффективны при построении деревьев и имеют наибольшее влияние на целевую переменную. При построении дерева на каждом шаге для разбиения вершины на два узла ищется признак и пороговое значение для него, чтобы разброс значений целевой переменной в левом и правом узле был бы минимальным. Для задач регрессии используется MSE, то есть чем сильнее нам удалось снизить MSE при разбиении, тем более важным считается предиктор, ведь он помогает разделить выборку так, чтобы значения целевой переменной в каждом узле отличались друг от друга меньше всего. Для каждого отдельного дерева решений мы можем отобрать наиболее важные предикторы, отсортировав их по тому, насколько они уменьшали ошибку, когда проводилось разбиение, при этом уменьшение ошибки обязательно взвешивается по количеству наблюдений в узле. Для того чтобы определить важность каждого предиктора в случайном лесу, эта процедура выполняется для каждого дерева, а ее результаты затем усредняются.

Таблица 4. Частота выбора экзогенных предикторов моделью случайного леса

Предиктор	Частота выбора данного предиктора среди товарных групп экспорта	Предиктор	Частота выбора данного предиктора среди товарных групп импорта
Мировой индекс цен на сырьевые товары	35%	Мировой индекс цен на сырьевые товары	57%
CCI по России	26%	Цена на нефть Brent – Европа	50%

Цена на нефть Brent – Европа	25%	Мировая цена на кукурузу	35%
Индекс цен производителей: базовая органическая химия	21%	Реальный эффективный обменный курс рубля	35%
Индекс цен производителей: древесная масса	15%	ССИ по России	34%

Как можно видеть из приведенных в Табл. 4 данных, наиболее важным предиктором оказывается мировой индекс цен на сырьевые товары: модель выбирает его для трети категорий экспорта и почти для 60% товарных групп импорта. Кроме того, большую роль в обоих случаях играют цена на нефть и ССИ по России, публикуемый ОЭСР. В случае импорта важной переменной оказывается также реальный обменный курс.

6. Заключение

В работе апробированы популярные для работы в условиях проклятия размерности модели с целью наукастинга и построения прогноза темпов роста долларовых стоимостных объемов российского экспорта и импорта по товарным группам. Наиболее высокое качество прогнозов демонстрирует взвешенная модель методов машинного обучения. По RMSE, она превосходит модель ARIMA в прогнозах для 69% товарных групп экспорта и 58% товарных групп импорта. Для агрегированного экспорта и импорта, экспорта минерального топлива (27 товарная группа) и ряда других товарных групп модели удастся получить статистически значимо более качественные прогнозы, согласно тесту Диболда – Мариано.

Рассмотренные модели дают прогнозы, достаточно схожие с прогнозами Банка России при сопоставимых условиях. На интервале с III квартала 2019 г. по IV квартал 2020 г. взвешенная модель методов машинного обучения показывает более высокую точность наукастинга совокупного импорта по сравнению с прогнозами Банка России. Наиболее релевантные предикторы в модели случайного леса согласуются с теоретическими представлениями: наиболее часто выбираемым показателем оказывается мировой индекс цен на сырьевые товары.

Литература

1. Ведев А. Л., Дробышевский С. М., Кнобель А. Ю., Соколов И. А., Трунин П. В. Сценарии развития экономической ситуации в России в 2020-2021 гг. и вызовы экономической политики // Экономическое развитие России. 2020. Т. 27. № 5. С. 4-23.
2. Емельянов С. С. Моделирование экспорта и импорта Российской Федерации в системе прогнозно-аналитических расчетов // Проблемы прогнозирования. 2007. № 2. С. 116-126.

3. Baybuza I. Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 2018, vol. 77, no. 4, pp. 42-59.
4. Breiman L. Random forests. *Machine learning*, vol. 45, 2001, no. 1, pp. 5-32.
5. Chen T. G. XGB: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785-794.
6. Clarida R. H. Consumption, Import Prices, and the Demand for Imported Consumer Durables: A Structural Econometric Investigation. *The Review of Economics and Statistics*, 1996, vol. 78, no. 3, pp. 369-374.
7. Diebold F. X., Mariano R. S. Comparing predictive accuracy // *Journal of Business & economic statistics*. – 2002. – Т. 20. – №. 1. – С. 134-144.
8. Gareev M. Use of Machine Learning Methods to Forecast Investment in Russia. *Russian Journal of Money and Finance*, 2020, vol. 79, no. 1, pp. 33-56.
9. George E. I., McCulloch R. E. Variable selection via Gibbs sampling. *Journal of the American Statistical Association*, 1993, vol. 88, no. 423, pp. 881-889.
10. Jokubaitis S., Celov D., Leipus R. Sparse structures with LASSO through principal components: Forecasting GDP components in the short-run. *International Journal of Forecasting*, 2020 (forthcoming).
11. Koop G. M. Forecasting with medium and large Bayesian VARs. *Journal of Applied Econometrics*, 2013, vol. 28, no. 2, pp. 177-203.
12. Li, J., Chen, W. Forecasting macroeconomic time series: LASSO-based approaches and their forecast combinations with dynamic factor models. *International Journal of Forecasting*, 2014, vol. 30, no. 4, pp.996-1015.
13. Nicholson W. B., Matteson D. S., Bien J. VARX-L: Structured regularization for large vector autoregressions with exogenous variables. *International Journal of Forecasting*, 2017, vol. 33, no. 3, pp. 627-651.
14. Polbin A., Fokin N. Modeling the dynamics of import in the Russian Federation using the error correction model. *Applied Econometrics*, 2020, vol. 59, pp. 88-112.
15. Senhadji A. Time-series estimation of structural import demand equations: a cross-country analysis. *Staff Papers*, 1998, vol. 45, no. 2, pp. 236-268.
16. Senhadji A. Time series analysis of export demand equations: a cross-country analysis. *IMF staff papers*, 1999, vol. 46, no. 3, pp. 259-273.
17. Tibshirani R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1996, vol. 58, no. 1, pp. 267-288.

18. Zou H. H. Regularization and variable selection via the EN. *Journal of the royal statistical society: series B (statistical methodology)*, 2005, vol. 67, no. 2, pp. 301-320.

References

1. Baybuza I. (2018) Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 77(4), pp. 42-59.
2. Breiman L. (2001) Random forests. *Machine learning*, 45(1), pp. 5-32.
3. Chen T. G. (2016) XGB: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785-794.
4. Clarida R. H. (1996) Consumption, Import Prices, and the Demand for Imported Consumer Durables: A Structural Econometric Investigation. *The Review of Economics and Statistics*, 78(3), pp. 369-374.
5. Diebold, F. X., Mariano, R. S. (2002). Comparing predictive accuracy. *Journal of Business & economic statistics*, 20(1), pp. 134-144.
6. Emelyanov S. S. (2007) Modelirovanie eksporta i importa Rossijskoj Federacii v sisteme prognozno-analiticheskikh raschetov [Modeling of export and import of the Russian Federation in the system of forecasting and analytical calculations]. *Studies on Russian Economic Development*, 2, pp. 116-126.
7. Gareev M. (2020) Use of Machine Learning Methods to Forecast Investment in Russia. *Russian Journal of Money and Finance*, 79(1), pp. 33-56.
8. George E. I., McCulloch R. E. (1993) Variable selection via Gibbs sampling. *Journal of the American Statistical Association*, 88(423), pp. 881-889.
9. Jokubaitis S., Celov D., Leipus R. (2020) Sparse structures with LASSO through principal components: Forecasting GDP components in the short-run. *International Journal of Forecasting* (forthcoming).
10. Koop G. M. (2013) Forecasting with medium and large Bayesian VARs. *Journal of Applied Econometrics*, 28(2), pp. 177-203.
11. Li, J., Chen, W. (2014) Forecasting macroeconomic time series: LASSO-based approaches and their forecast combinations with dynamic factor models. *International Journal of Forecasting*, 30(4), pp.996-1015.
12. Nicholson W. B., Matteson D. S., Bien J. (2017) VARX-L: Structured regularization for large vector autoregressions with exogenous variables. *International Journal of Forecasting*, 33(3), pp. 627-651.
13. Polbin, A., & Fokin, N. (2020). Modeling the dynamics of import in the Russian Federation using the error correction model. *Applied Econometrics*, 59, pp. 88-112.
14. Senhadji A. (1998) Time-series estimation of structural import demand equations: a cross-country analysis. *Staff Papers*, 45(2), pp. 236-268.

15. Senhadji A. (1999) Time series analysis of export demand equations: a cross-country analysis. *IMF staff papers*, 46(3), pp. 259-273.
16. Tibshirani R. (1996) Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), pp. 267-288.
17. Vedev A., Drobyshevsky S., Knobel A., Sokolov I., Trunin P. (2020) Scenarii razvitiya ekonomicheskoy situacii v Rossii v 2020-2021 gg. i vyzovy ekonomicheskoy politiki [Scenarios of the development of economic situation in Russia in 2020–2021 and challenges for economic policy]. *Russian Economic Development*, 27(5), pp. 4-23.
18. Zou H. H. (2005) Regularization and variable selection via the EN. *Journal of the royal statistical society: series B (statistical methodology)*, 67(2), pp. 301-320.

Приложение

Таблица П1. Полный перечень предикторов с указанием источника данных

Название	Описание	Источник
RBRUBIS	Реальный эффективный обменный курс рубля (Real Broad Effective Exchange Rate for Russia)	FRED ⁹ (тикер в названии)
MCOILBRETEU	Цена на нефть: Брент – Европа (Crude Oil Prices: Brent – Europe)	FRED (тикер в названии)
MHHNGSP	Цена на газ: Генри Хаб – США (Henry Hub Natural Gas Spot Price)	FRED (тикер в названии)
WPU0911	Индекс цен производителей: древесная масса (Producer Price Index by Commodity: Pulp, Paper, and Allied Products: Wood Pulp)	FRED (тикер в названии)
PWHEAMTUSDM	Мировая цена на зерно (Global Price of Wheat)	FRED (тикер в названии)
PPICMM	Индекс цен производителей: цветные металлы (Producer Price Index by Commodity: Metals and Metal Products: Primary Nonferrous Metals)	FRED (тикер в названии)
PCOPPUUSD	Мировая цена на медь (Global price of Copper)	FRED (тикер в названии)
PALUMUSD	Мировая цена на алюминий (Global price of Aluminum)	FRED (тикер в названии)
WPU101	Индекс цен производителей: железо и сталь (Producer Price Index by Commodity: Metals and Metal Products: Iron and Steel)	FRED (тикер в названии)
PMAIZMTUSD	Мировая цена на кукурузу (Global price of Corn)	FRED (тикер в названии)
PRUBBUSDM	Мировая цена на резину (Global price of Rubber)	FRED (тикер в названии)

⁹ <https://fred.stlouisfed.org/>

PMETAINDEXM	Мировая цена на металлы (Global price of Metal index)	FRED (тикер в названии)
PCU325199325199P	Индекс цен производителей: базовая органическая химия (Producer Price Index by Industry: All Other Basic Organic Chemical Manufacturing: Primary Products)	FRED (тикер в названии)
PCU33913391	Индекс цен производителей: медицинское оборудование (Producer Price Index by Industry: Medical Equipment and Supplies Manufacturing)	FRED (тикер в названии)
WPS022	Индекс цен производителей: мясо, птица и рыба (Producer Price Index by Commodity: Processed Foods and Feeds: Meats, Poultry, and Fish)	FRED (тикер в названии)
WPU011	Индекс цен производителей: фрукты и овощи (Producer Price Index by Commodity: Farm Products: Fruits and Melons, Fresh/Dry Vegetables and Nuts)	FRED (тикер в названии)
PALLFNFINDEXM	Мировой индекс цен на сырьевые товары (Global Price Index of All Commodities)	FRED (тикер в названии)
GOLDAMGBD228NLBM	Цена на золото на Лондонской бирже на 10:30 (Gold Fixing Price 10:30 A.M. (London time) in London Bullion Market)	FRED (тикер в названии)
IPP	Индекс промышленного производства	Единый архив экономических и социологических данных (http://sophist.hse.ru)
cli_RUS, cli_OECD, cli_OECDE, cli_G7, cli_USA, cli_CHN, cli_EA19	Композитные опережающие индикаторы (Composite Leading Indicator, CLI) для России, ОЭСР, ОЭСР+, Б7, США, Китая, еврозоны	https://data.oecd.org

bci_RUS, bci_OECD, bci_OECDE, bci_G7, bci_USA, bci_CHN, bci_EA19	Индексы предпринимательской уверенности (Business Confidence Index, BCI) для России, ОЭСР, ОЭСР- Европа, G7, США, Китая, еврозоны	https://data.oecd.org
cci_RUS, cci_OECD, cci_OECDE, cci_G7, cci_USA, cci_CHN, cci_EA19	Индексы потребительской уверенности (Consumer Confidence Index, CLI) России, ОЭСР, ОЭСР Европа, G7, США, Китая, еврозоны	https://data.oecd.org

Таблица П2. Множества, использованные для поиска оптимальных гиперпараметров

Модель	Название гиперпараметра	Множество для поиска
EN	l1_ratio (вес модели LASSO)	{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1}
	alpha (сила штрафа коэффициентов)	{0, 0.0001, 0.0005, 0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1, 5, 10, 50, 100, 500, 1000}
Random Forest	min_samples_leaf (минимальное число наблюдений в конечных вершинах (листах))	{1, 2, 3, 4, 5}
	max_features (максимальное число признаков, по которым ищется разбиение в каждой вершине)	{5, 10, 15, 20, 30, 40}
	min_samples_split (минимальное количество наблюдений, необходимое для разделения внутреннего листа)	{2, 3, 4, 5}
XGBoost	n_estimators (число деревьев)	{20, 50, 100, 200, 500}
	max_depth (максимальная глубина каждого дерева)	{1, 3, 5, 7}
	reg_alpha (сила L1-регуляризации на веса)	{0, 0.0001, 0.001, 0.01, 0.01, 0.1, 1, 10}
	colsample_bytree (доля признаков от общего числа, используемая для построения каждого дерева)	{0.1, 0.3, 0.5, 0.7, 0.9}

Товарные категории в Табл. ПЗ и П4 перечислены в порядке убывания указанной в скобках средней доли их объемов в совокупном экспорте/импорте в период с I квартала 2015 г. по IV квартал 2020 г.; жирным шрифтом выделены модели, сильнее всего превосходящие ARIMA. В скобках через точку с запятой указаны р-значения одностороннего теста Диболда – Мариано. Нулевая гипотеза состоит в том, что модели обладают одинаковой прогностической способностью, альтернативная гипотеза – рассматриваемая модель превосходит модель ARIMA. Первое число в скобках – р-значение теста для квадратичной функции потерь, второе число в скобках – р-значение теста для модульной функции потерь.

Таблица ПЗ. Отношение RMSE используемых моделей к RMSE ARIMA и р-значение теста Диболда – Мариано для основных групп экспорта

Категории экспорта и их доли в совокупном экспорте	EN/ ARIMA	RF/ARIMA	XGB/ ARIMA	SSVS/ ARIMA	AR-LASSO/ ARIMA	WM/ ARIMA
Совокупный экспорт	0,848 (0,141; 0,057)	0,703 (0,004; 0,015)	0,803 (0,170; 0,054)	1,803 (0,993; 0,990)	1,998 (0,865; 0,796)	0,638 (0,005; 0,006)
Топливо минеральное, нефть и продукты их перегонки; битуминозные вещества; воски минеральные (65,7%)	0,842 (0,121; 0,087)	0,679 (0,016; 0,018)	0,664 (0,052; 0,014)	1,825 (0,995; 0,996)	0,583 (0,018; 0,015)	0,621 (0,008; 0,002)
Черные металлы (5,2%)	0,973 (0,411; 0,490)	0,731 (0,035; 0,139)	0,824 (0,117; 0,264)	1,960 (0,905; 0,960)	1,125 (0,750; 0,779)	0,796 (0,047; 0,132)
Жемчуг природный или культивированный, драгоценные или полудрагоценные камни, драгоценные металлы, металлы, плакированные драгоценными металлами, и изделия из них; бижутерия; монеты (2,5%)	1,148 (0,811; 0,326)	1,187 (0,837; 0,593)	0,996 (0,491; 0,405)	1,480 (0,889; 0,867)	1,223 (0,873; 0,933)	1,087 (0,721; 0,386)
Удобрения (2,0%)	1,300 (0,909; 0,928)	1,279 (0,881; 0,891)	1,549 (0,951; 0,942)	2,164 (0,994; 0,994)	1,596 (0,910; 0,872)	1,221 (0,856; 0,917)
Древесина и изделия из нее; древесный уголь (1,9%)	1,799 (0,852; 0,867)	1,471 (0,925; 0,905)	1,394 (0,878; 0,812)	2,540 (0,977; 0,997)	3,303 (0,998; 0,999)	1,181 (0,774; 0,738)
Реакторы ядерные, котлы, оборудование и механические устройства; их части (1,9%)	0,835 (0,072; 0,091)	1,003 (0,511; 0,371)	1,092 (0,772; 0,793)	1,550 (0,996; 0,999)	1,105 (0,761; 0,537)	0,887 (0,110; 0,122)
Алюминий и изделия из него (1,8%)	1,171 (0,863; 0,871)	1,113 (0,849; 0,797)	1,278 (0,905; 0,850)	1,427 (0,959; 0,980)	1,088 (0,806; 0,652)	1,070 (0,732; 0,612)
Продукты неорганической химии; соединения неорганические или органические драгоценных металлов,	0,797 (0,091; 0,056)	0,839 (0,173; 0,142)	1,001 (0,502; 0,364)	1,251 (0,847; 0,720)	0,854 (0,176; 0,049)	0,849 (0,159; 0,092)

редкоземельных металлов, радиоактивных элементов или изотопов (1,5%)						
Злаки (1,3%)	1,114 (0,815; 0,644)	1,009 (0,516; 0,432)	1,048 (0,666; 0,777)	2,510 (0,992; 0,998)	1,293 (0,983; 0,975)	1,000 (0,501; 0,317)
Медь и изделия из нее (1,2%)	0,968 (0,411; 0,322)	1,047 (0,554; 0,274)	1,186 (0,913; 0,721)	2,487 (0,894; 0,956)	0,968 (0,416; 0,122)	0,930 (0,240; 0,133)

Таблица П4. Отношение RMSE используемых моделей к RMSE ARIMA и р-значение теста Диболда – Мариано для основных групп импорта

Категории импорта их доли в совокупном импорте	EN/ ARIMA	RF/ ARIMA	XGB/ ARIMA	SSVS/ ARIMA	AR-LASSO/ ARIMA	WM/ ARIMA
Совокупный импорт	0,821 (0,161; 0,130)	1,070 (0,491; 0,511)	0,930 (0,352; 0,421)	1,021 (0,545; 0,722)	0,947 (0,375; 0,487)	0,690 (0,022; 0,013)
Реакторы ядерные, котлы, оборудование и механические устройства; их части (17,9%)	0,841 (0,187; 0,222)	1,032 (0,734; 0,645)	1,082 (0,689; 0,623)	1,115 (0,803; 0,803)	0,815 (0,163; 0,197)	0,803 (0,115; 0,090)
Средства наземного транспорта, кроме железнодорожного или трамвайного подвижного состава, и их части и принадлежности (12,0%)	1,258 (0,828; 0,947)	1,587 (0,969; 0,989)	1,594 (0,943; 0,963)	1,455 (0,955; 0,991)	2,552 (0,992; 0,998)	1,217 (0,817; 0,907)
Электрические машины и оборудование, их части; звукозаписывающая и звуковоспроизводящая аппаратура, аппаратура для записи и воспроизведения телевизионного изображения и звука, их части и принадлежности (11,4%)	0,819 (0,135; 0,076)	0,875 (0,147; 0,262)	0,753 (0,131; 0,210)	1,009 (0,515; 0,589)	1,962 (0,962; 0,993)	0,705 (0,044; 0,032)
Фармацевтическая продукция (4,6%)	1,010 (0,528; 0,230)	0,827 (0,042; 0,020)	0,875 (0,016; 0,018)	0,901 (0,197; 0,297)	0,879 (0,032; 0,235)	0,873 (0,009; 0,014)
Пластмассы и изделия из них (3,8%)	1,165 (0,818; 0,850)	1,011 (0,539; 0,394)	0,903 (0,233; 0,373)	1,362 (0,958; 0,977)	1,153 (0,790; 0,816)	0,879 (0,235; 0,254)
Инструменты и аппараты оптические, фотографические, кинематографические, измерительные, контрольные, прецизионные, медицинские или хирургические; их части и принадлежности (2,8%)	1,604 (0,959; 0,979)	0,975 (0,434; 0,644)	1,142 (0,824; 0,922)	1,333 (0,856; 0,913)	2,623 (0,996; 0,999)	1,027 (0,717; 0,892)
Изделия из черных металлов (2,6%)	0,825 (0,126; 0,107)	1,049 (0,767; 0,629)	1,000 (0,502; 0,422)	1,706 (0,967; 0,943)	1,047 (0,605; 0,634)	0,853 (0,117; 0,164)

Черные металлы (2,2%)	0,915 (0,302; 0,617)	0,985 (0,318; 0,524)	1,065 (0,755; 0,652)	1,263 (0,917; 0,945)	1,030 (0,571; 0,892)	0,858 (0,100; 0,339)
Мясо и пищевые мясные субпродукты (2,2%)	1,172 (0,770; 0,930)	0,899 (0,397; 0,759)	1,147 (0,739; 0,985)	1,120 (0,626; 0,806)	1,264 (0,764; 0,885)	0,971 (0,498; 0,929)
Съедобные фрукты и орехи; кожура цитрусовых плодов или корки дынь (2,2%)	1,051 (0,576; 0,331)	1,241 (0,857; 0,791)	1,478 (0,935; 0,863)	1,070 (0,646; 0,725)	1,040 (0,613; 0,752)	1,181 (0,767; 0,681)

Таблица П5. Формулы расчета метрик качества наукаста при сравнении с прогнозами Банка России

Метрика	Формула
Среднеквадратическая ошибка (Root Mean Square Error, RMSE)	$\sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}}$
Средняя абсолютная ошибка (Mean Absolute Error, MAE)	$\frac{1}{n} \sum_{i=1}^n \hat{y}_i - y_i $
Средняя абсолютная процентная ошибка (Mean Absolute Percentage Error, MAPE)	$\frac{1}{n} \sum_{i=1}^n \frac{ \hat{y}_i - y_i }{y_i}$
Среднее абсолютное процентное отклонение (Percentage Mean Absolute Deviation, PMAD)	$\frac{\sum_{i=1}^n \hat{y}_i - y_i }{\sum_{i=1}^n y_i }$

Примечание: y_i и \hat{y}_i – фактическое и спрогнозированное значения i -го наблюдения соответственно, n – общее число наблюдений для расчета.