

Моделирование показателей денежно-кредитной системы РФ при разнонаправленных сценариях динамики нефтяного рынка

Цель работы – построение математических моделей, описывающих взаимосвязи между рыночными индикаторами, имеющими ключевое значение для экономики России, и макроэкономическими показателями денежно-кредитной системы.

Материалы и методы. Для решения задачи моделирования в работе были использованы методы описания математических моделей, изначально применяющиеся в теории автоматического управления к механическим системам: линейные дискретные передаточные функции, модели пространства состояний и нелинейные модели Гаммерштейна-Винера. В качестве инструментария исследования, для идентификации моделей использовался функционал System Identification Toolbox программного пакета Matlab, который обычно используется для анализа технических систем. По известным входному и выходному сигналам производился подбор математической модели. Для оценки точности выбора модели рассчитывалось нормальное среднеквадратичное отклонение для промоделированного и заданного выходного сигнала. В качестве исходных данных использовались временные ряды макроэкономических и рыночных показателей в период с 2008 по 2018 гг.

Результаты. В работе были разработаны две модели прогнозирования. Модель-1 описывает последовательный переход от цен на нефть и курса доллара США к оценке валового внутреннего продукта, денежного агрегата M2 и кредитной задолженности. Зависимости между экономическими параметрами математи-

чески описываются линейными дискретными передаточными функциями. Модель-2 отличается последовательностью двух последних переходов: от валового внутреннего продукта к кредитам, а затем к денежному агрегату M2. Кроме того, два последних перехода математически описываются нелинейными моделями Гаммерштейна-Винера. Результатом моделирования являются прогнозы по направлению трендов и значениям макроэкономических показателей денежно-кредитной системы на временном горизонте в 3, 7 и 12 лет при двух разнонаправленных сценариях динамики нефтяного рынка.

Заключение. Несмотря на близкие значения при оценке точности каждой из построенных моделей, в прогнозе они дают схожие результаты по соответствию сценариев, но разные темпы роста. Изменения цен на нефть однозначно сказываются на макроэкономических показателях денежно-кредитной системы, что свидетельствует о способности разработанных моделей давать корректные прогнозы по направлениям трендов кредитной активности и денежной массы. В дальнейших исследованиях предполагается возможность перехода от макроэкономических показателей к более частным составляющим на мезо- и микроуровнях.

Ключевые слова: прогнозирование, математическая модель, экономическая кибернетика, идентификация модели, временные ряды

Alexey A. Pekhterev

Plekhanov Russian University of economics, Moscow, Russia

Modeling of monetary and credit system indicators of the Russian Federation in multidirectional scenarios of oil market dynamics

The purpose of research – to build mathematical models that describe interrelationships between the key market indicators, significant for the Russian economy, and macroeconomic indicators of the monetary system.

Materials and methods. In this study, we applied methods of model description, mostly used in control theory, meant for technical engineering, such as linear discrete transfer functions, space-state models and nonlinear Hammerstein-Wiener models. To identify these models, we used System Identification Toolbox from Matlab software package, mostly used for mechanical systems' analysis. Based on the known input and output signals, a mathematical model was estimated. Time series of macroeconomic and market indicators for the period from January 10, 2008 to January 10, 2018 were used for identification.

Results. Two prediction models were designed in this work. The first model describes a sequential transfer from the oil price and dollar-to-ruble exchange rate to the gross domestic product, then to M2 and then to loans. Dependencies between economic parameters are described by linear discrete transfer functions. There is only one

difference in the second model's general structure: the sequence of the last two transitions from the gross domestic product to loans, and then to M2. In addition, nonlinear Hammerstein-Wiener models describe last two transitions in the second model. As a result, predictions for macroeconomic indicators' trends were given on different time horizons: three, seven and twelve years and with two differently directed scenarios of the oil market.

The conclusion. Despite close values in the models accuracy estimation, they give similar results for matching scenarios, but different growth rates in general, in the forecast. Such a result in scenarios shows, that a sharp fall in oil prices has a stronger impact on given macroeconomic and market indicators, which, in its turn, shows the capability of the models to make correct trend predictions. In further studies, it is possible to move from macroeconomic indicators to their more particular components at meso- and micro levels.

Keywords: forecasting, mathematical model, economic cybernetics, model identification, time series

Введение

В данной статье исследуется возможность использования математического аппарата и инструментария теории автоматического управления (ТАУ) для решения задач прогнозирования экономических процессов, происходящих в динамических нелинейных экономических системах. Нахождение математических зависимостей между рыночными индикаторами и макроэкономическими показателями денежно-кредитной системы позволит проводить имитационное моделирование и давать прогнозы по поведению экономических систем. Данный вопрос изучался многими исследователями, которые предлагали свои подходы к построению моделей [1–4]. Кроме того, важным аспектом таких исследований является именно инструментарий, помогающий исследователю. Математическое моделирование экономических систем можно считать областью близкой к экономфизике или экономической кибернетике, которые предполагают использование методологии физики и исследования технических систем к анализу экономических данных [5]. Поэтому в данном исследовании для решения поставленной задачи используется технический инструментарий. Подобный метод объединения экономики и кибернетики был рассмотрен Кугаенко А. [6, 7]. Но в нашем исследовании для идентификации моделей, приближенных к реальной практике, вместо аналитического вывода уравнений зависимостей, были использованы методы, позволяющие находить взаимосвязи между уже имеющимися временными рядами.

В качестве метода получения прогнозов в исследовании был использован метод математического (динамического) моделирования. Данный метод достаточно давно применяется

для решения задач теории автоматического регулирования (ТАР), т.е. для решения технических задач. Однако методы формального описания динамики механических систем, а также методы решения задач регулирования вполне подходят для описания динамики экономических процессов, так как по своей сути являются лишь математическим аппаратом. При получении прогноза методом математического моделирования результатом являются не будущие состояния систем, а прогнозы изменений их параметров, как реакции на предполагаемые внешние воздействия.

1. Математическое описание динамической модели

Изменение состояния динамических систем во времени принято математически описывать системой дифференциальных уравнений. В теории автоматического управления (ТАУ) для описания таких систем используются передаточные функции или модели пространства состояний, которые представляют собой дифференциальный оператор, выражающий связь между входом и выходом линейной стационарной (параметры которой не меняются во времени) системы. Зная входной сигнал системы и передаточную функцию, можно восстановить выходной сигнал. По своей сути – это просто другой способ записи системы дифференциальных уравнений.

Линейной передаточной функцией называется отношение [8]:

$$W(s) = \frac{Y(s)}{U(s)} \quad (1)$$

$U(s)$ и $Y(s)$ – преобразования Лапласа функций $u(t)$ и $y(t)$
 $u(t)$ – входной сигнал;
 $y(t)$ – выходной сигнал.

Преобразование Лапласа определяется следующим образом:

$$U(s) = L\{u(t)\} = \int_0^{\infty} u(t) \cdot e^{-st} dt \quad (2)$$

$$Y(s) = L\{y(t)\} = \int_0^{\infty} y(t) \cdot e^{-st} dt \quad (3)$$

Преобразование Лапласа используется для перехода от функции вещественного переменного (изображение) к функции комплексного переменного (оригинал), что значительно облегчает описание динамических систем, так как в этом случае линейные дифференциальные уравнения становятся алгебраическими.

Дискретной передаточной функцией называется отношение [9]:

$$W(z) = \frac{Y(z)}{U(z)} \quad (4)$$

$u(k)$ – входной сигнал, который представляет собой дискретную функцию, определенную в заданные моменты времени k ;

$y(k)$ – выходной сигнал, который представляет собой дискретную функцию, определенную в заданные моменты времени k ;

$U(z)$ и $Y(z)$ – их z -преобразования;

Z – преобразование дискретной функции определяется следующим образом:

$$U(z) = Z\{u(k)\} = \sum_{k=0}^{\infty} u(k) \cdot z^{-k} \quad (5)$$

$$Y(z) = Z\{y(k)\} = \sum_{k=0}^{\infty} y(k) \cdot z^{-k} \quad (6)$$

Смысл z -преобразования для дискретных функций аналогичен использованию преобразования Лапласа для линейных, но для случая наличия дискретизации сигналов в системе (например, дискретные сигналы в микропроцессорах).

Для более наглядного описания динамических систем в теории автоматического управления используется пространство состояний [10]. Описание приставляет собой систему дифференциальных (разно-

стных — для дискретных систем) уравнений первого порядка (7), связанных между собой.

$$\begin{cases} x(k+1) = A \cdot x(k) + B \cdot u(k) \\ y(k) = C \cdot x(k) + D \cdot u(k) \end{cases} \quad (7)$$

$x(k)$ — вектор состояния системы;

$u(k)$ — вектор входных сигналов;

$y(k)$ — вектор выходных сигналов;

A — матрица состояний системы;

B — матрица входов;

C — матрица выходов;

D — матрица прямого прохождения;

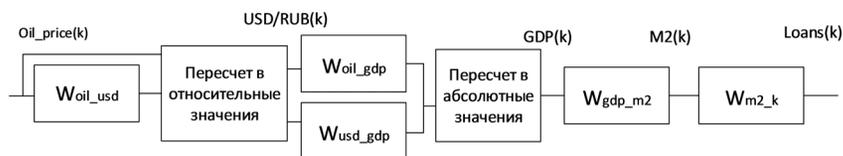
T_s — период дискретизации.

Обычно в ТАУ каждое состояние вектора $x = (x_1, x_2, \dots, x_n)$ имеет какой-либо физический смысл и описывает состояние какого-либо параметра динамической системы в каждый момент времени (например, угловое ускорение, угловая скорость, угол поворота вала и т.д.).

1.1. Идентификация параметров моделей

В нашем случае, методы, которые обычно используются в ТАУ, применены к задаче идентификации моделей, которыми можно описать зависимости между временными рядами. На рис. 1 представлена общая структурная схема модели прогнозирования рыночных и макроэкономических индикаторов (Модели-1).

Для идентификации параметров моделей использовался System Identification Toolbox в



Обозначения: Oil_price(k) — входной сигнал, цены на нефть; USD/RUB(k) — выходной сигнал, курс доллара; GDP(k) — входной сигнал, ВВП, руб.; M2(k) — выходной сигнал, денежный агрегат M2; Loans(k) — выходной сигнал, кредитная задолженность;

Рис. 1. Общая структурная схема Модели-1

программном пакете MATLAB. Обычно данный инструментарий используется для построения моделей динамических систем на основе реальных измеренных входных и выходных данных.

В нашем случае в качестве входных и выходных данных последовательно использовались дневные данные по ценам на нефть и курсу доллара США, годовые данные по ВВП и месячные — по денежному агрегату M2 и кредитам в рублях, в промежуток с 2008 по 2018 год. По необходимости данные были интерполированы кубическим сплайном и представляют собой дискретные функции с периодом дискретизации 0.01 [11]. Поэтому каждый отдельный блок на схеме представляет собой дискретную передаточную функцию. При этом 1 секунда времени моделирования соответствует временному промежутку в 100 дней.

На рис. 2 представлены графики соответствия заданного выходного сигнала и выходного сигнала идентифицированной модели для случая перехо-

да от денежного агрегата M2 к кредитам.

Порядок модели выбирался перебором из моделей в виде линейных дискретных передаточных функций и нелинейных моделей, которые входят в инструментарий (нелинейной авторегрессией (NARX) и моделями типа Гаммерштейна-Винера с различными видами нелинейностей). NARX обычно используются для предсказания следующих точек временного ряда, по имеющимся прошлым данным. При наличии пары временных рядов вход — выход, NARX может служить фильтром, который сглаживает нелинейную составляющую входного сигнала, таким образом фильтруя шум [12]. Так как в нашем случае, желательно сохранить нелинейные свойства сигналов, как экономических показателей, то целесообразнее использовать модели вида Гаммерштейна-Винера [13].

Исследование показало, что при автоматической идентификации нелинейные модели хотя и часто давали лучший результат по совпадению вы-

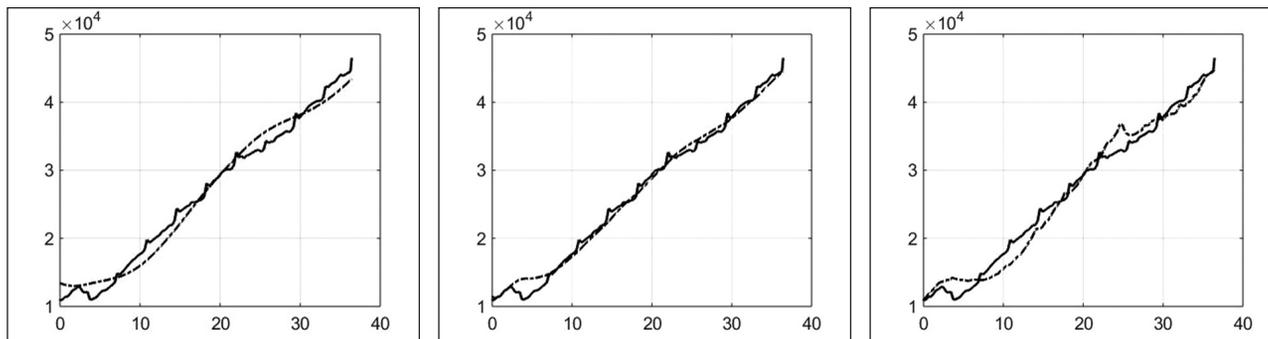


Рис. 2. Идентификация моделей по заданному выходу в System Identification Toolbox

ходов, излишне «переобучались» и некорректно работали при моделировании разных прогнозных сценариев. Поэтому для описания первой модели были выбраны модели в виде дискретных передаточных функций (системы линейных разностных уравнений).

Оценка работы модели в System Identification Toolbox производилась с помощью нормального среднеквадратичного отклонения (8) (NRMSE).

$$fit(i) = 100 \times \left(1 - \frac{\|xref(:,i) - x(:,i)\|}{\|xref(:,i) - mean(xref(:,i))\|} \right) \quad (8)$$

$xref$ – опорная функция;
 x – оцениваемая функция;
 fit – оценка в процентах.

Блок модели «OIL-price – USD/RUB»

Передаточная функция блока модели (9):

$$W_{oil_usd} = \frac{-0.07484 + 0.1496 \cdot z^{-1} - 0.07474 \cdot z^{-2}}{1 - 2.533 \cdot z^{-1} + 2.066 \cdot z^{-2} - 0.5329 \cdot z^{-3}} = \frac{USD_RUB(z)}{Oil_price(z)} \quad (9)$$

Параметры блока в пространстве состояний:

$$A = \begin{pmatrix} 1.5074 & -0.2318 & -0.5512 \\ 1 & 0 & 0 \\ 0 & 0.5 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0.25 \\ 0 \\ 0 \end{pmatrix} \quad C = (-0.2140 \quad 0.2141 \quad 0) \quad D = 0 \quad T_s = 0.01$$

Блок модели «USD/RUB, OIL-price – GDP»

Для идентификации параметров блока модели выходные и выходные сигналы были пересчитаны в формат «год к году» по формуле (10), чтобы избавиться от сезонности.

$$Oil_price_year(k) = \frac{Oil_price(k+365) - Oil_price(k)}{Oil_price(k)} \quad (10)$$

$Oil_price_year(k)$ – входной сигнал, цена нефти;
 $USD_RUB_year(k)$ – входной сигнал, цена нефти;

$GDP_year(k)$ – выходной сигнал, курс доллара;

Передаточные функции блока модели (11–12):

$$W_{oil_gdp} = \frac{0.0001259 \cdot z^{-1}}{1 - 2 \cdot z^{-1} + z^{-2}} = \frac{GDP_year(z)}{Oil_price_year(z)} \quad (11)$$

$$W_{usd_gdp} = \frac{0.002587 \cdot z^{-1}}{1 - 1.998 \cdot z^{-1} + 0.9983 \cdot z^{-2}} = \frac{GDP_year(z)}{USD_RUB_year(z)} \quad (12)$$

Параметры модели в пространстве состояний:

$$A = \begin{pmatrix} 1.9980 & -0.9980 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1.9980 & -0.9980 \\ 0 & 0 & 1 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0.0156 & 0 \\ 0 & 0.0313 \\ 0 & 0 \\ 0 & 0 \end{pmatrix} \quad C = (-0.0077 \quad 0.0078 \quad -0.0113 \quad 0.0114) \quad D = (8.8765e - 05 \quad 1.3608e - 04) \quad T_s = 0.01$$

Блок модели «GDP – M2»

Передаточная функция блока модели (13):

$$W_{gdp_m2} = \frac{-0.6358 + 1.294 \cdot z^{-1} - 0.6586 \cdot z^{-2}}{1 - 1.828 \cdot z^{-1} + 0.8278 \cdot z^{-2}} = \frac{M2(z)}{GDP(z)} \quad (13)$$

Параметры блока модели в пространстве состояний:

$$A = \begin{pmatrix} 1.8277 & -0.8278 \\ 1 & 0 \\ 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0.5 \\ 0 \end{pmatrix} \quad C = (0.2648 \quad -0.2646) \quad D = -0.6358 \quad T_s = 0.01$$

Блок модели «M2 – Loans»

Передаточная функция блока модели (14):

$$W_{m2_k} = \frac{8.868e \cdot 10^{-6} \cdot z^{-1}}{1 - 1.998 \cdot z^{-1} + 0.997 \cdot z^{-2}} = \frac{Loans(z)}{M2(z)} \quad (14)$$

Параметры блока модели в пространстве состояний:

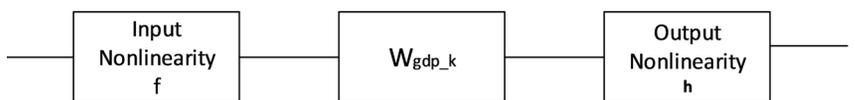
$$A = \begin{pmatrix} 1.9977 & -0.9977 \\ 1 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0.0039 \\ 0 \end{pmatrix} \quad C = (0.0023 \quad 0) \quad D = 0 \quad T_s = 0.01$$

1.2. Альтернативный метод получения прогноза

Другим вариантом построения модели прогнозирования является нахождение зависимостей между временными рядами в следующем порядке: «Цены на нефть и курс доллара – ВВП – кредитная задолженность – денежный агрегат M2». При этом меняются



Рис. 3. Общая структурная схема Модели-2



Обозначения: f – входная нелинейность, которая преобразует входной сигнал $u(t)$ к виду $w(t) = f(u(t))$;
 h – выходная нелинейность, которая преобразует выходной сигнал $x(t)$ к $y(t) = h(x(t))$;
 W_{gdp_k} – линейная передаточная функция перехода от $w(t)$ к $x(t)$

Рис. 4. Модель Гаммерштейна-Винера

местами только два последних блока модели-1, описанной выше. На рис. 3 представлена обобщенная структурная схема такой модели (Модель-2).

В ходе исследования было выявлено, что нелинейные модели типа Гаммерштейна-Винера дают лучший результат по сравнению с линейными дискретными моделями.

Модель Гаммерштейна-Винера имеет структуру, представленную на рис. 4.

Использование модели такого типа строится на предположении, что если выходной сигнал системы нелинейным образом зависит от входного сигнала(-ов), то целесообразно разбить эту зависимость на две или более составляющих. В данном случае, динамика системы описывается линейной передаточной функцией (как описано ранее), а нелинейные свойства выходного временного ряда определяются нелинейными блоками [14, 15].

Блок модели «GDP – Loans»

Блок модели имеет структуру, описанную выше. Для входного сигнала ВВП вычисляется соответствующее значение его нелинейной входной функции. Затем полученный сигнал преобразуется линейной передаточной функцией. Для преобразованного сигнала вычисляется соответствующее значение нелинейной выходной функции. Полученный сигнал является выходом блока модели и представляет собой временной ряд по кредитной задолженности. Ниже приведены виды линейного и нелинейных составляющих модели (рис. 5).

$GDP(k)$ – входной сигнал, ВВП, руб.;
 $Loans(k)$ – выходной сигнал, кредиты;

Линейная передаточная функция блока модели (15):

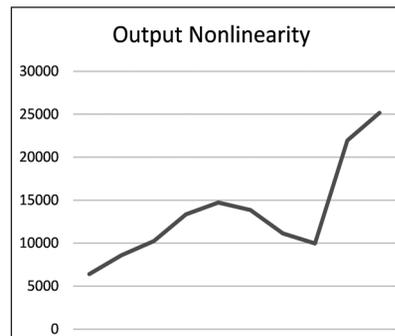
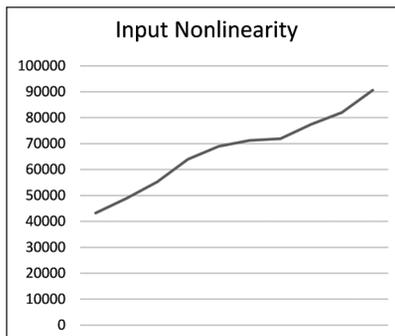


Рис. 5. Входная и выходная нелинейности для блока модели «GDP – Loans»

$$W_{gdp_k} = \frac{z^{-1} - 0.0697 \cdot z^{-2}}{1 - 0.2038 \cdot z^{-1} - 0.8777 \cdot z^{-2} - 0.2678 \cdot z^{-3}} \quad (15)$$

Входная и выходная нелинейные функции блока модели, показанные на рис. 5, представляют собой кусочно-линейные функции, состоящие из 9 отрезков.

Блок модели «Loans – M2»

Блок модели имеет аналогичную структуру, которая была описана выше.

$Loans(k)$ – входной сигнал, ВВП, руб.;

$M2(k)$ – выходной сигнал, кредиты;

Линейная передаточная функция блока модели (16):

$$W_{k_m2} = \frac{z^{-1} - 0.9899 \cdot z^{-2}}{1 - 0.9902 \cdot z^{-1} - 0.5355 \cdot z^{-2} - 0.5316 \cdot z^{-3}} \quad (16)$$

Входная и выходная нелинейные функции блока модели, показанные на рис. 6, представляют собой кусочно-линейные функции, состоящие из 4 и 8 отрезков соответственно.

Вид нелинейностей подбирался перебором, точки излома

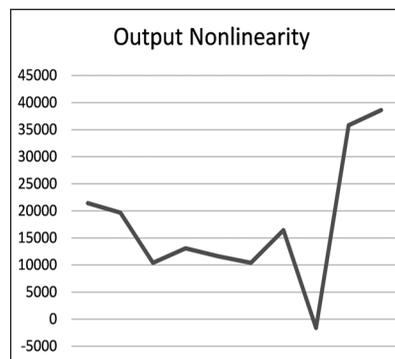
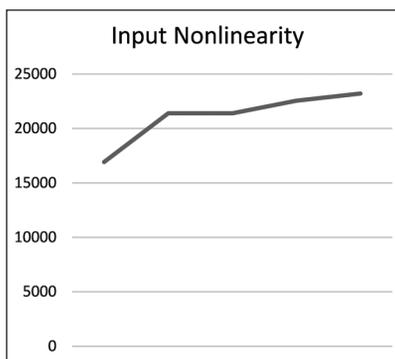


Рис. 6. Входная и выходная нелинейности для блока модели «Loans – M2»

подбираются автоматически методом оптимизации, выбранным программным инструментарием, так же как и параметры линейной части.

1.3. Сравнение двух моделей

На рис. 7 и 8 представлены результаты моделирования агрегата M2 двумя предложенными способами на временном промежутке, на котором производилась идентификация моделей (сплошная линия – реальный M2).

Расчет нормального среднеквадратичного отклонения для разных вариантов моделей для M2 дает следующие результаты: 89.15% для модели-1 и 88.99% для модели-2. Таким образом, модель-1 в этом смысле дает лучшие результаты, однако модель-2 при этом предполагает моделирование не только тренда, но и нелинейной составляющей сигнала.

2. Результаты моделирования

Моделирование определенных сценариев развития проводилось в программном

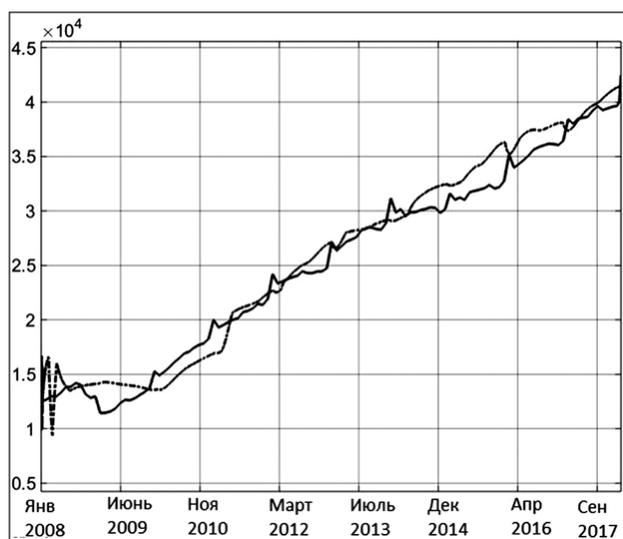


Рис. 7. Выходы модели-1 по агрегату M2

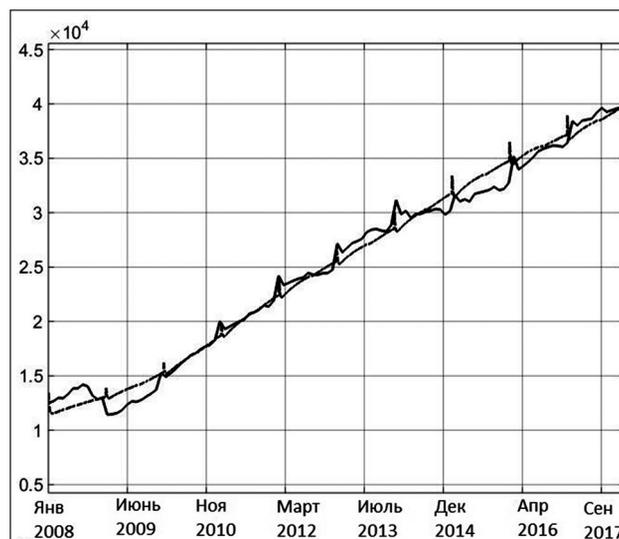


Рис. 8. Выход модели-2 по агрегату M2

пакете Simulink MATLAB. В качестве входных данных рассматривались два варианта развития цен на нефть: линейное монотонное возрастание с текущего значения (февраль 2018 года) до 100 долл./баррель (сценарий А); и линейное монотонное убывание до 10 долл./баррель (сценарий Б). При этом моделирование ситуации проводилось на 3, 7 и 12 лет вперед (см. таблицу 1).

Анализируя результаты, можно сделать вывод, что обе модели показывают рост показателей денежно-кредитной системы, при этом — более быстрые темпы роста ожидаются при сценарии-А.

Заключение

В данной работе была исследована возможность применения к задаче прогнозирования экономических временных рядов методов кибернетики, а именно, метод математического моделирования и идентификации моделей. Для решения поставленной задачи использовались инструменты Simulink и System Identification Toolbox программного пакета Matlab. Были идентифицированы две прогнозные модели, описывающие взаимосвязи между временными рядами цен на нефть и курса доллара США,

во многом определяющих динамику номинального ВВП РФ, денежного агрегата M2 и кредитной задолженности перед банковской системой. Результатом исследования являются прогнозы на временных горизонтах 3, 7 и 12 лет при разнонаправленных сценариях изменения цен на нефть. Анализируя результаты моделирования, можно сделать вывод, что резкое падение цен на нефть сильнее сказывается на исследуемых макроэкономических показателях денежно-кредитной системы, чем их рост. Это, в свою очередь, свидетельствует о способности полученных моделей давать корректные прогнозы по направлениям исследуемых трендов. На основе полученных моделей целесообразно разработать программу оперативного прогнозирования показателей денежно-кредитной системы по любым конфигурациям заложенных исследователем сценариев динамики нефтяного рынка и свободной вариативности временного горизонта. В дальнейших исследованиях предполагается переход от прогнозирования макроэкономических показателей к более частным составляющим денежно-кредитной системы на мезо- и микроуровнях.

Таблица 1

Результаты моделирования

	Сценарий	Результаты (последняя точка прогноза)			
		USD/RUB	ВВП, млрд руб.	Кредитная задолженность, млрд руб.	M2, млрд руб.
Модель-1	А до 2021 г.	56,53	106 152,1	54 478,6	47 852,2
	А до 2025 г.	66,98	114 457,8	63 661,9	54 879,6
	А до 2030 г.	78,99	120 467,9	70 785,3	60 390,3
	Б до 2021 г.	72,66	101 024,3	54 106,6	46 825,3
	Б до 2025 г.	74,97	108 639,8	62 062,9	53 134,5
	Б до 2030 г.	79,22	113 798,9	68 364,5	58 024,0
Модель-2	А до 2021 г.	56,53	106 152,1	52 465,49	46 925,0
	А до 2025 г.	66,98	114 457,8	57 258,54	50 066,5
	А до 2030 г.	78,99	120 467,9	60 565,74	51 640,3
	Б до 2021 г.	72,66	101 024,3	49 842,0	44 781,2
	Б до 2025 г.	74,97	108 639,8	54 120,1	47 538,3
	Б до 2030 г.	79,22	113 798,9	56 990,8	48 808,6

Литература

1. Петров А.А., Поспелов И.Г., Шананин А.А. Опыт математического моделирования экономики. М.: Энергоатомиздат, 1996. 544 с. ISBN 5-283-03169-1.
2. Краснощёков П.С., Петров А. А. Принципы построения моделей. 2-е изд., пересм. и доп. М.: Фазис, 2000. 412 с. ISBN 5-7036-0061-8.
3. Красс И. А. Математические модели экономической динамики. М.: Советское радио, 1976. 280 с.
4. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Основы моделирования и первичная обработка данных. М.: Финансы и статистика, 1983. 471 с.
5. Романовский М.Ю., Романовский Ю.М. Введение в эконофизику. Статистические и динамические модели. М., 2007. ISBN 978-5-93972-637-5
6. Кугаенко А.А. Экономическая кибернетика. М.: Вузовская книга, 2015. 880 с.
7. Кугаенко А.А. Методы динамического моделирования в управлении экономикой. М.: Вузовская книга, 2005. 456 с.
8. Бесекерский В.А., Попов Е.П. Теория систем автоматического регулирования. 2-е изд. М.: Наука, 1972. 768 с.
9. Иванов В.А., Ющенко А.С. Теория дискретных систем автоматического управления. М.: МГТУ им. Н. Э. Баумана, 2015. 352 с.
10. Dorf P., Bishop R. Современные системы управления. Пер. с англ. Б. И. Копылова. М.: Лаборатория базовых знаний, 2002. 832 с.
11. Волков Е.А. Глава 1. Приближение функций многочленами. § 11. Сплайны // Численные методы. Учеб. пособие для вузов. 2-е изд., испр. М.: Наука, 1987. С. 63–68.
12. Diaconescu E. The use of NARX neural networks to predict chaotic time series. Wseas Transactions on computer research, 2008. 3(3). P. 182–191.
13. Болквадзе Г. Р. Модель Гаммерштейна-Винера в задачах идентификации стохастических систем, Автомат. и телемех. 2003. № 9. P. 60–76. Autom. Remote Control. 64:9. 20031418–1431.
14. Billings S.A. Identification of Nonlinear Systems: A Survey. IEE Proceedings Part D. 1980. 127(6). P. 272–285
15. Haber R., Keviczky L. Nonlinear System Identification-Input Output Modeling Approach. Kluwer, 1980. Vols I & II.
16. Yu F., Mao Zh., Jia M., Yuan P., Recursive Parameter Identification of Hammerstein-Wiener Systems With Measurement Noise // Signal Process. 2014. 105. P. 137–147.
17. Домашенко Д.В. Имитационное моделирование уровня сбалансированной задолженности клиентов банковской системы России // Вестник РЭУ им. Г.В. Плеханова. 2016. № 1. С. 27–34.

References

1. Petrov A.A., Pospelov I.G., Shananin A.A. Opyt matematicheskogo modelirovaniya ekonomiki. Moscow: Energoatomizdat, 1996. 544 p. ISBN 5-283-03169-1. (In Russ.)
2. Krasnoshchekov P. S., Petrov A. A. Printsipy postroeniya modeley. 2nd ed. Moscow: Fazis, 2000. 412 p. ISBN 5-7036-0061-8. (In Russ.)
3. Krass I. A. Matematicheskie modeli ekonomicheskoy dinamiki. Moscow: Sovetskoe radio, 1976. 280 p. (In Russ.)
4. Ayvazyan S.A., Enyukov I.S., Meshalkin L.D. Prikladnaya statistika: Osnovy modelirovaniya i pervichnaya obrabotka dannykh. Moscow: Finansy i statistika, 1983. 471 p. (In Russ.)
5. Romanovskiy M.Yu., Romanovskiy Yu.M. Vvedenie v ekonofiziku. Statisticheskie i dinamicheskie modeli. Moscow, 2007. ISBN 978-5-93972-637-5 (In Russ.)
6. Kugaenko A.A. Ekonomicheskaya kibernetika. Moscow: Vuzovskaya kniga, 2015. 880 p. (In Russ.)
7. Kugaenko A.A. Metody dinamicheskogo modelirovaniya v upravlenii ekonomikoy. Moscow: Vuzovskaya kniga, 2005. 456 p. (In Russ.)
8. Besekerskiy V.A., Popov E.P. Teoriya sistem avtomaticheskogo regulirovaniya. 2nd ed. Moscow: Nauka, 1972. 768 p. (In Russ.)
9. Ivanov V.A., Yushchenko A.S. Teoriya diskretnykh sistem avtomaticheskogo upravleniya. Moscow: MGTU im. N. E. Baumana, 2015. 352 p. (In Russ.)
10. Dorf R., Bishop R. Sovremennye sistemy upravleniya. Tr. fr. Eng. B. I. Kopylova. Moscow: Laboratoriya bazovykh znaniy, 2002. 832 p. (In Russ.)
11. Volkov E. A. Glava 1. Priblizhenie funktsiy mnogochlenami. § 11. Splayny. Chislennyye metody. Ucheb. posobie dlya vuzov. 2nd ed., ispr. Moscow: Nauka, 1987. P. 63–68. (In Russ.)
12. Diaconescu E. The use of NARX neural networks to predict chaotic time series. Wseas Transactions on computer research, 2008. 3(3). P. 182–191.
13. Bolkvadze G. R. Model' Gammershteyna-Vinera v zadachakh identifikatsii stokhasticheskikh sistem, Avtomat. i telemekh. 2003. No. 9. P. 60–76. Autom. Remote Control. 64:9. 20031418–1431. (In Russ.)
14. Billings S.A. Identification of Nonlinear Systems: A Survey. IEE Proceedings Part D. 1980. 127(6). P. 272–285
15. Haber R., Keviczky L. Nonlinear System Identification-Input Output Modeling Approach. Kluwer, 1980. Vols I & II.
16. Yu F., Mao Zh., Jia M., Yuan P., Recursive Parameter Identification of Hammerstein-Wiener Systems With Measurement Noise. Signal Process. 2014. 105. P. 137–147.
17. Domashchenko D.V. Imitatsionnoe modelirovanie urovnya sbalansirovannoy zadolzhennosti klientov bankovskoy sistemy Rossii. Vestnik REU im. G.V. Plekhanova. 2016. No. 1. P. 27–34. (In Russ.)

18. Домашенко Д.В. Взаимосвязь экономического роста и уровня монетизации экономики в странах нефтегазового экспорта: выводы для России // Экономические и социальные перемены: факты, тенденции, прогноз. 2016. № 1. С. 96–107.

19. Вятченников Д.Н., Кособуцкий В.В., Носенко А.А., Плотникова Н.В. Идентификация нелинейных динамических объектов во временной области // Вестник ЮУрГУ. 2006. № 14. С. 66–70.

20. G.L. Plett Adaptive inverse control of linear and nonlinear systems using dynamic neural networks in IEEE Transactions on Neural Networks. Vol. 14. No. 2. P. 360–376, Mar 2003. doi: 10.1109/TNN.2003.809412.

18. Domashchenko D.V. Vzaimosvyaz' ekonomicheskogo rosta i urovnya monetizatsii ekonomiki v stranakh neftegazovogo eksporta: vyvody dlya Rossii. Ekonomicheskie i sotsial'nye peremeny: fakty, tendentsii, prognoz. 2016. No. 1. P. 96–107. (In Russ.)

19. Vyatchennikov D.N., Kosobutskiy V.V., Nosenko A.A., Plotnikova N.V. Identifikatsiya nelineynykh dinamicheskikh ob"ektov vo vremennoy oblasti. Vestnik YuUrGU. 2006. No. 14. P. 66–70. (In Russ.)

20. G.L. Plett Adaptive inverse control of linear and nonlinear systems using dynamic neural networks in IEEE Transactions on Neural Networks. Vol. 14. No. 2. P. 360–376, Mar 2003. doi: 10.1109/TNN.2003.809412.

Сведения об авторе

Алексей Александрович Пехтерев

М.н.с., НЛ «Исследования денежно-кредитной системы и анализа финансовых рынков»
Российский экономический университет
им. Г.В. Плеханова, Москва, Россия
Эл. почта: lexpekhterev@gmail.com

Information about the author

Alexey A. Pekhterev

Junior researcher, Science laboratory «Monetary systems study and financial markets analysis»
Plekhanov Russian University of economics,
Moscow, Russia
E-mail: lexpekhterev@gmail.com