

## ГИБРИДНАЯ НЕЙРОСЕТЕВАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ПОВЕДЕНИЯ РЫНКА

А. И. БЕЛЬЗЕЦКИЙ<sup>1)</sup>

<sup>1)</sup>БелМежКомИнвест, ул. Игнатенко, 7, 220030, г. Минск, Беларусь

Для повышения качества прогнозирования поведения рынка предложена гибридная модель, объединяющая модели организованной целостности рынка и искусственной нейронной сети. Гибридная модель позволяет учесть неоднородную пространственно-временную структуру рынка во взаимодействии с внешней средой, принять в расчет нелинейные эффекты и выполнить достоверный прогноз для основных показателей рынка на несколько будущих периодов. Представлен пример нейросетевого прогнозирования поведения финансового рынка, подтверждающий качество гибридной модели.

**Ключевые слова:** рынок; гибридная модель; нейронная сеть; прогнозирование; поведение; организованная целостность.

## HYBRID NEURAL NETWORK MODEL FOR FORECASTING MARKET BEHAVIOUR

A. I. BELZETSKY<sup>a</sup>

<sup>a</sup>BelMezhKomInvest, 7 Ignatenko Street, Minsk 220030, Belarus

For improving the quality of forecasting market behaviour, a hybrid model that combines models of organised market integrity and an artificial neural network is proposed. The hybrid model allows us to take into account the heterogeneous spatiotemporal structure of the market in interaction with the external environment, to take into account non-linear effects and to make a reliable forecast of the main market indicators for several future periods. An example of neural network forecasting of financial market behaviour, confirming the quality of the hybrid model is presented.

**Keywords:** market; hybrid model; neural network; forecasting; behaviour; organised integrity.

### Введение

Важнейшим инструментом государственного регулирования является прогнозирование процессов социально-экономического развития. Зарубежный опыт свидетельствует, что среди других областей исследования экономики прогнозирование социально-экономических систем занимает первое место (составляет свыше 53 %) [1]. В условиях социально ориентированной регулируемой государством

#### Образец цитирования:

Бельзецкий АИ. Гибридная нейросетевая модель прогнозирования поведения рынка. *Журнал Белорусского государственного университета. Экономика.* 2023;2:25–38. EDN: QZHLZE

#### For citation:

Belzetsky AI. Hybrid neural network model for forecasting market behaviour. *Journal of the Belarusian State University. Economics.* 2023;2:25–38. Russian. EDN: QZHLZE

#### Автор:

*Анатолий Иосифович Бельзецкий* – кандидат технических наук; директор.

#### Author:

*Anatoly I. Belzetsky*, PhD (engineering); director. *bmki07@mail.ru*

рыночной экономики объективная необходимость прогнозирования обусловлена ее неспособностью к саморегулированию, общественным характером производства и необходимостью поддерживать его рациональную структуру, деятельностью государства как субъекта рынка, усложнением межрыночных и межотраслевых связей.

Для повышения качества прогнозирования временных рядов разработаны гибридные модели, которые интегрируют модели нейронных сетей с традиционными статистическими или эконометрическими методами. Основная идея гибридизации моделей прогнозирования заключается в объединении их достоинств. При этом, как правило, используются преимущества линейного и нелинейного моделирования. Известны примеры прогнозирования финансовых временных рядов, сочетающие модели нейронных сетей (ANN) с методом экспоненциального сглаживания (ES) [2; 3], моделью интегрированной скользящей средней с авторегрессией (ARIMA) [4; 5], сезонной моделью ARIMA (SARIMA) [6], моделью векторной авторегрессии (VAR) [4], моделью обобщенной линейной авторегрессии (GLAR) [7], моделью экспертных систем [8; 9], моделью множественной линейной регрессии (MLR) [10] и др. Результаты численных экспериментов на реальных данных показали, что гибридная модель обеспечивает повышение точности прогноза по сравнению с точностью любой из единичных моделей [3; 11].

Неспособность нейронных сетей одинаково хорошо обрабатывать как линейные, так и нелинейные составляющие сдерживает использование гибридных моделей для решения задач прогнозирования [5; 12], поскольку в процессе обучения нейронной сети линейные компоненты «затмевают» или «подавляют» нелинейные составляющие. Кроме того, сложность обучения нейронной сети возрастает с увеличением количества входов как куб размерности входного вектора [13], поэтому невозможно подать на вход нейронной сети произвольное количество показателей с тем, чтобы нейронная сеть сама определила, какие из них наиболее значимы. Наконец, гибридные модели, как правило, являются слишком абстрактными, так как предназначены исключительно для прогнозирования временных рядов. Они не рассматривают сам объект прогнозирования, его состав, структуру и взаимосвязи с внешней средой, а также не учитывают погрешности и модель измерения временных рядов.

Настоящая статья посвящена повышению качества прогнозирования поведения рынка за счет устранения отмеченных недостатков. Предложена гибридная модель, объединяющая инновационную модель рынка как организованной целостности [14] и модель искусственной нейронной сети<sup>1</sup>. На конкретном примере рассмотрены практические вопросы реализации, выбора параметров и архитектуры гибридной нейросетевой модели.

### Гибридная нейросетевая модель

Нейронная сеть строится по принципам организации и функционирования ее биологического аналога [13; 15]. Она состоит из множества слоев нейронов (рис. 1). В каждом из слоев нейроны независимы друг от друга, но выход каждого нейрона текущего слоя соединен синаптическими связями со всеми входами нейронов следующего слоя. По функциональному признаку слои нейронной сети могут быть разбиты на входной, выходной и скрытый. Входной слой принимает информацию и распределяет ее между нейронами следующего слоя. Выходной слой обрабатывает информацию, полученную от предыдущего слоя, и выдает окончательный результат прогнозирования. Скрытые слои расположены между входным и выходным слоями. Они обрабатывают информацию, полученную от предыдущего слоя, и передают ее следующему слою. Тем самым в нейронной сети информация распространяется последовательно от входного слоя через скрытые слои к выходному слою. Поэтому такая нейронная сеть получила название «нейронная сеть прямого распространения» [16].

Обычно модель нейронной сети принимает входной вектор  $Y$  и выдает выходной вектор  $R$ . Взаимосвязь между  $Y$  и  $R$  определяется архитектурой нейронной сети. В матричной форме выражение для расчета выходных значений нейронной сети с двумя скрытыми слоями через ее входные значения имеет следующий вид:

$$R = F^{(3)}(W^{(3)}F^{(2)}(W^{(2)}F^{(1)}(W^{(1)}Y))),$$

где  $R = \{R_j(t+1), R_j(t+2), \dots, R_j(t+T)\}^T$  – вектор выходных значений,  $R_j$  –  $j$ -й исходный прогнозируемый показатель,  $T$  – горизонт прогнозирования,  $t$  – символ транспонирования матрицы;  $F^{(i)}$  – оператор нелинейного преобразования  $i$ -го слоя;  $W^{(i)}$  – матрица весовых коэффициентов  $i$ -го слоя;  $Y = \{Y_1(t), Y_1(t-1), \dots, Y_1(t-q), \dots, Y_n(t), Y_n(t-1), \dots, Y_n(t-q)\}^T$  – вектор входных значений,  $Y_j(t)$  – значение  $j$ -го интегрального показателя целостности в момент  $t$ ,  $n$  – число интегральных показателей целостности, подаваемых на вход нейронной сети,  $q$  – глубина погружения или число последовательных значений интегрального показателя целостности, одновременно подаваемых на вход нейронной сети.

<sup>1</sup>Далее в работе для обозначения понятия «искусственная нейронная сеть» будет использоваться словосочетание «нейронная сеть».

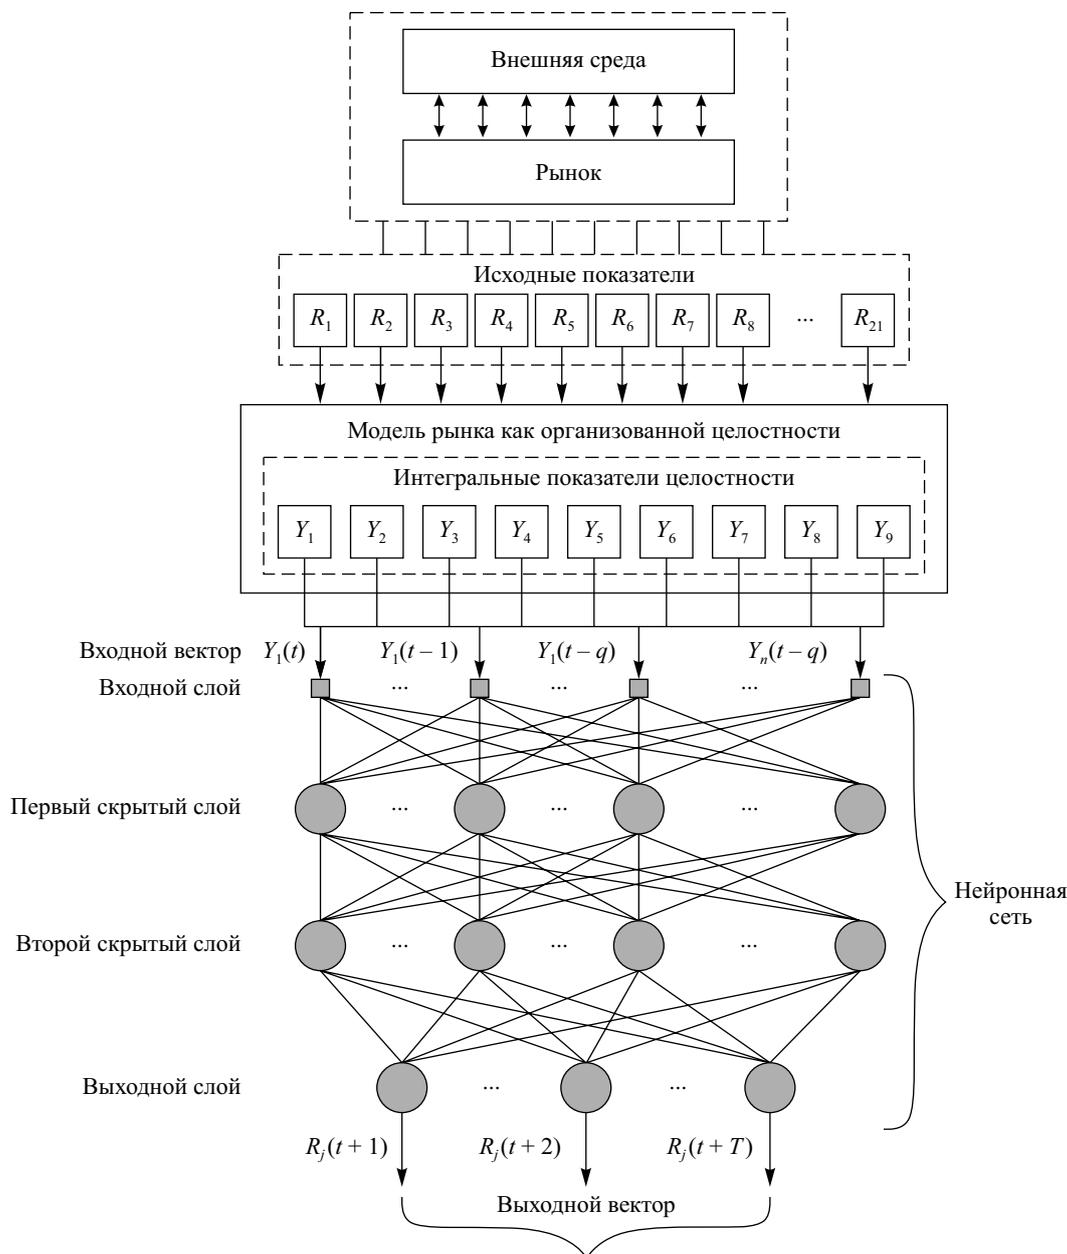


Рис. 1. Гибридная нейросетевая модель поведения рынка

Fig. 1. Hybrid neural network model of market behaviour

В гибридной нейросетевой модели векторы входных значений формируются на основе рядов данных интегральных показателей целостности, полученных по результатам измерения организованной целостности рынка. С позиций методологии холизма «рынок – это организованная целостность, в которой субъекты рынка регулярно реализуют свои противоречивые интересы посредством обмена товарами и услугами» [14, с. 87]. Модель рынка как организованной целостности во взаимосвязи с внешней средой имеет следующий вид [14]:

$$A = \frac{V\Sigma}{\sqrt{n-1}}, \quad (1)$$

$$Y = U\sqrt{n-1}, \quad (2)$$

где  $A$  – матрица целостных образов;  $V$  – матрица правых сингулярных векторов;  $\Sigma = \text{diag}\{\sigma_1, \sigma_2, \dots, \sigma_m\}$  – матрица сингулярных чисел;  $Y$  – матрица интегральных показателей целостности;  $U$  – матрица левых сингулярных векторов;  $n$  – число значений исходного ряда данных (объем выборки).

Диагональная матрица сингулярных чисел, а также матрицы левых и правых сингулярных векторов определяются на основе сингулярного разложения матрицы рядов данных исходных показателей ( $Z$ ) [17; 18]

$$Z = U\Sigma V^T. \tag{3}$$

В контексте решения задачи измерения целостности элементы сингулярного разложения матрицы рядов данных исходных показателей имеют следующий смысл. Матрица правых сингулярных векторов представляет собой матрицу собственных векторов матрицы произведения исходных рядов данных ( $Z^T Z$ ) [19]. Столбцы матрицы собственных векторов ортогональны и определяют положение новой системы координат, оси которой совпадают с интегральными показателями целостности.

Матрица левых сингулярных векторов представляет собой матрицу собственных векторов матрицы произведения исходных рядов данных ( $ZZ^T$ ) [19]. В ее столбцах расположены нормированные и ортогональные ряды интегральных показателей целостности. Сингулярные числа, расположенные на диагонали матрицы сингулярных чисел, играют роль масштабирующих множителей. Каждое сингулярное число соответствует конкретному интегральному показателю, ряд данных которого расположен в соответствующем столбце матрицы левых сингулярных векторов. Поэтому сингулярные числа определяют весомость интегральных показателей целостности: чем больше сингулярное число, тем больше размах (амплитуда) колебаний ряда данных интегрального показателя целостности и тем более значима информация об измеряемой целостности, которую он содержит.

Модели (1) и (2) описывают неоднородную пространственно-временную организованную целостность рынка и внешней среды. Главным результатом измерения выступает матрица целостных образов, поскольку она включает в себя все сведения о свойствах, составе и структуре организованной целостности рынка. Матрица интегральных показателей целостности содержит в столбцах ряды данных, которые характеризуют поведение целостностей. Причем к одной целостности может относиться несколько интегральных показателей, если эта целостность имеет несколько степеней свободы. Матрица рядов данных интегральных показателей целостности используется для формирования входных образов нейронной сети, применяемых как для ее обучения, так и для прогнозирования поведения рынка.

### Программная реализация гибридной нейросетевой модели

Для реализации гибридной нейросетевой модели на языке Visual Basic.NET платформы «Microsoft Visual Studio 2015» [20] разработано приложение *Neural Networks*. Визуальный интерфейс данного приложения построен на основе элемента управления TabControl Visual Basic.NET [21], который содержит вкладки «Исходные данные», «Нейронные сети», «Сертификат качества», «Графики» и «Результаты» (рис. 2).



Рис. 2. Внешний вид элемента управления приложения *Neural Networks*

Fig. 2. The appearance of the application *Neural Networks*

Вкладка «Исходные данные» предназначена для выбора исходных рядов данных, установки основных параметров приложения, а также для предварительной диагностики и масштабирования рядов данных исходных показателей. Во вкладке «Нейронные сети» задается архитектура нейронной сети (количество внутренних слоев, число нейронов в каждом внутреннем слое, функции активации нейронов),

а также устанавливается алгоритм обучения и выбираются критерии завершения обучения нейронной сети. Во вкладке «Сертификат качества» в текстовой форме выводятся основные характеристики качества нейросетевого моделирования: коэффициент детерминации, среднеквадратичная ошибка моделирования, суммарный квадрат ошибки обучения. Вкладки «Графики» и «Результаты» предназначены для визуального анализа результатов нейросетевого моделирования в графической и табличной форме.

### Основные этапы гибридного нейросетевого прогнозирования

Гибридное нейросетевое прогнозирование поведения рынка включает следующие основные этапы.

**Этап 1:** выбор прогнозируемых показателей, характеризующих поведение рынка. В состав исходных показателей включаются все возможные показатели, характеризующие экзогенные факторы, которые влияют или связаны с прогнозируемыми показателями. Число исходных показателей и единицы их измерения не имеют значения.

**Этап 2:** подготовка и предварительная обработка исходных данных. Ряды данных исходных показателей масштабируются путем расчета относительных приращений и стандартизируются посредством их приведения к нулевому среднему значению и единичной дисперсии.

**Этап 3:** измерение организованной целостности рынка. Результатом этого измерения является матрица целостных образов, которая содержит сведения о свойствах, составе и структуре организованной целостности рынка и внешней среды.

**Этап 4:** спектральный анализ организованной целостности рынка. На основе измеренной матрицы целостных образов анализируются спектры собственных значений и форм целостностей и определяется состав организованной целостности рынка и внешней среды, а также находятся интегральные показатели целостностей, относящиеся к прогнозируемым показателям. Для прогнозирования отбираются только те интегральные показатели целостности, которые связаны или влияют на прогнозируемый показатель. Таким образом, необходимая для прогнозирования информация сжимается, а число показателей, подаваемых на вход нейронной сети, существенно снижается (чаще всего на величину от одного до трех).

**Этап 5:** расчет динамических рядов данных интегральных показателей целостности и их нормализация. Нормализация – это пересчет рядов данных интегральных показателей целостностей к диапазону от  $-1$  до  $1$  с учетом условия, что в скрытых слоях нейронной сети будут использоваться функции активации гиперболического тангенса. Ряды данных интегральных показателей целостности независимы, т. е. коэффициенты корреляции между ними равны нулю. Это способствует повышению производительности и качества обучения нейронной сети.

**Этап 6:** формирование входных и выходных образов для обучения нейронной сети. На этом этапе используется метод скользящего окна. Ширину скользящего окна (глубину погружения), т. е. количество значений интегрального показателя, одновременно подаваемых на вход нейронной сети, рекомендуется принимать равной трем. Меньшее значение ширины скользящего окна снижает точность, а большее значение увеличивает время обучения нейронной сети без существенного повышения точности. Для формирования выходных образов нейронной сети рекомендуется использовать исходный, немасштабированный и нестандартизованный, но нормализованный ряд данных прогнозируемого показателя, который сдвинут относительно входного ряда на величину периода прогнозирования. Предлагается использовать один прогнозируемый показатель, а горизонт прогнозирования выбирать равным трем периодам.

**Этап 7:** выбор архитектуры нейронной сети. Рекомендуется использовать нейронную сеть прямого распространения с двумя скрытыми слоями с числом нейронов в скрытых слоях, равным числу нейронов во входном слое, с функциями активации гиперболического тангенса для нейронов скрытых слоев и с линейной функцией активации для нейронов выходного слоя. Каждый нейрон текущего слоя связан со всеми нейронами следующего слоя, а входная информация передается в прямом направлении от входного слоя через скрытые слои к выходному слою.

**Этап 8:** обучение нейронной сети и оценка качества обучения. На этом этапе нейронная сеть обучается посредством настройки ее весовых коэффициентов. При обучении нейронной сети хорошие результаты дает «стандартный» алгоритм обратного распространения ошибки [22]. В процессе обучения нейронная сеть проверяется на ее соответствие историческому ряду данных прогнозируемого показателя, который не использовался для обучения, с последующим проведением корректировки параметров нейронной сети, если результаты обучения оказались неудовлетворительными. Для оценки качества нейронной сети используется серия ошибок между историческим рядом данных и ретропрогноznым рядом данных прогнозируемого показателя, рассчитанным с помощью обученной нейронной сети. При этом используются следующие статистические показатели: коэффициент детерминации ( $R^2$ ), среднеквадратичное

отклонение ошибки, сумма квадратов ошибок. Модель обученной нейронной сети запоминается для дальнейшего ее использования.

**Этап 9:** нормальная работа гибридной нейросетевой модели, расчет значений прогнозируемого показателя для новых данных. Следует иметь в виду, что чем больше горизонт прогнозирования, тем ниже точность прогноза. Кроме того, нейросетевая модель будет давать ошибочный прогноз, если при прогнозировании встречаются факторы, которые не учитывались при обучении нейронной сети.

**Этап 10:** анализ результатов прогнозирования. На этом этапе выявляются основные факторы, которые определяют поведение рынка в будущем, и разрабатываются соответствующие рекомендации.

### Прогнозирование поведения финансового рынка

Рассмотрим пример гибридного нейросетевого прогнозирования поведения финансового рынка на основе исторических данных за 2017–2021 гг. В состав исходного множества включались показатели, характеризующие внешнюю среду и основные сегменты финансового рынка: валютный рынок, рынок межбанковских кредитов, рынок банковских вкладов (депозитов), рынок банковских кредитов.

В качестве показателей внешней среды использовались месячный объем валового внутреннего продукта ( $R_1$ ), текущие цены; месячный темп роста потребительских цен ( $R_2$ ), %; месячный темп роста цен производителей промышленной продукции ( $R_3$ ), %; месячный объем экспорта товаров и услуг ( $R_4$ ), млн долл. США; месячный объем импорта товаров и услуг ( $R_5$ ), млн долл. США; месячный объем доходов консолидированного бюджета (без ФСЗН) ( $R_6$ ), млн руб.; месячная выручка от реализации продукции, товаров, работ, услуг ( $R_7$ ), млн руб.; денежные доходы населения нарастающим итогом с начала года ( $R_8$ ), млн руб.; средний за месяц агрегат рублевой денежной массы  $M2^*$  ( $R_9$ ), млн руб.

Для анализа валютного рынка использовались показатели среднемесячного официального курса белорусского рубля по отношению к российскому рублю (за 100 российских рублей) ( $R_{10}$ ), к доллару США (за 1 долл.) ( $R_{11}$ ), к евро (за 1 евро) ( $R_{12}$ ). Для характеристики рынка межбанковских кредитов использовались показатели среднемесячных процентных ставок, по которым банки привлекали (размещали) кредиты, вклады (депозиты) на межбанковском рынке в национальной валюте на 1 день ( $R_{13}$ ), 2 дня ( $R_{14}$ ) и 4–7 дней ( $R_{15}$ ). В качестве характеристик рынка банковских вкладов (депозитов) использовались показатели среднемесячных процентных ставок в национальной валюте по обязательствам банков ( $R_{16}$ ), по всем срочным вкладам (депозитам) ( $R_{17}$ ) и по новым вкладам (депозитам) ( $R_{18}$ ). Для рынка банковских кредитов выбирались показатели среднемесячных процентных ставок кредитов банков в национальной валюте по новым кредитам без учета межбанковских кредитов, но с учетом льготных кредитов ( $R_{19}$ ); по всем кредитам, но без учета межбанковских и льготных кредитов ( $R_{20}$ ); по новым кредитам, но без учета межбанковских и льготных кредитов ( $R_{21}$ ).

Ряды данных исходных показателей  $R_1, R_2, \dots, R_{21}$  масштабировались путем расчета их относительных приращений (темпов прироста), после чего масштабированные ряды данных центрировались и приводились к единичной дисперсии, т. е. подвергались статистической стандартизации. Масштабирование исходных рядов данных предназначено для исключения из расчета ложных корреляций между рядами данных, которые обусловлены трендами во времени, для устранения влияния единиц измерения исходных рядов данных на результаты расчета, а также для исключения влияния пропусков данных на результаты измерения. Кроме того, вычисление относительных приращений позволяет преобразовать нестационарные временные ряды данных в стационарные [23, с. 199]. Для проверки стационарности исходных рядов данных применялся расширенный тест Дики – Фуллера с константой и линейным трендом [24, с. 382] при уровне значимости 0,05. Из представленных в табл. 1 данных следует, что использование процедуры масштабирования и стандартизации позволило преобразовать все исходные ряды данных в форму, соответствующую стационарному процессу.

Таблица 1

Стационарность рядов данных исходных показателей  $R_1, R_2, \dots, R_{21}$

Table 1

Stationarity of data series of initial indicators  $R_1, R_2, \dots, R_{21}$

Ряд данных	$R_1$	$R_2$	$R_3$	$R_4$	$R_5$	$R_6$	$R_7$	$R_8$	$R_9$	$R_{10}$
Исходный	+	+	–	–	–	+	+	+	–	–
Масштабированный и стандартизованный	+	+	+	+	+	+	+	+	+	+

Окончание табл. 1  
Ending of the table 1

Ряд данных	$R_{11}$	$R_{12}$	$R_{13}$	$R_{14}$	$R_{15}$	$R_{16}$	$R_{17}$	$R_{18}$	$R_{19}$	$R_{20}$	$R_{21}$
Исходный	–	–	+	–	+	–	–	–	–	–	–
Масштабированный и стандартизованный	+	+	+	+	+	+	+	+	+	+	+

Примечание. Информация, представленная в табл. 1–4, а также на рис. 3–7, разработана автором на основе данных Национального банка Республики Беларусь<sup>2</sup>.

Для измерения целостности важна теснота связей между исходными показателями. Для ее оценки использовался коэффициент сферичности Бартлетта – Уилкса [25; 26]. Результаты вычислений показали, что расчетное значение  $\chi^2$ -критерия Уилкса, равное 1200, значительно превышает его критическое значение, равное 245, при уровне значимости 0,05. Следовательно, между исходными показателями существуют тесные связи и изучаемая среда представляет собой целостность.

Для оценки того, насколько теснота связей между исходными показателями объясняется целостностями, применялся критерий Кайзера – Мейера – Олкина (КМО) [27]. Его допустимые значения должны находиться в следующих пределах:  $0,5 < \text{КМО} \leq 1$  [28]. Расчетное значение критерия КМО равняется 0,662 и находится в допустимых пределах. Таким образом, модель для измерения целостности среды финансового рынка может быть полезна для прогнозирования рядов данных исходных показателей.

В табл. 2 представлены результаты измерения целостности финансового рынка и внешней среды за 2017–2021 гг. Матрица целостных образов рассчитывалась путем сингулярного разложения исходных рядов данных по формулам (1) и (3). Из-за больших размеров матрица целостных образов разбита на две части: матрицу целостных образов главных целостностей (см. табл. 2) и матрицу целостных образов прочих целостностей.

Таблица 2

## Матрица целостных образов финансового рынка и внешней среды

Table 2

## Matrix of integral images of the financial market and the external environment

Показатели	Главные целостности								
	$I_1$	$I_2$	$I_3$	$I_4$	$I_5$	$I_6$	$I_7$	$I_8$	$I_9$
$R_1$	–0,217	0,325	0,233	–0,686	–0,360	–0,248	–0,066	–0,164	0,123
$R_2$	0,156	–0,135	–0,329	–0,319	–0,136	0,660	–0,439	–0,164	0,099
$R_3$	0,293	–0,257	–0,238	–0,648	0,205	0,259	–0,023	0,303	–0,313
$R_4$	–0,399	0,743	0,236	0,162	0,064	0,260	–0,129	–0,065	0,125
$R_5$	–0,447	0,764	0,268	–0,016	0,060	0,243	–0,016	0,108	–0,011
$R_6$	–0,171	0,129	0,291	–0,626	–0,477	–0,326	0,087	0,091	0,091
$R_7$	–0,453	0,752	0,310	–0,107	0,184	0,164	0,037	0,019	0,018
$R_8$	–0,485	0,662	0,338	–0,060	0,107	0,092	0,057	0,125	–0,219
$R_9$	–0,497	–0,219	0,084	–0,469	–0,490	0,017	–0,080	–0,154	–0,269
$R_{10}$	–0,048	–0,138	–0,288	–0,125	–0,492	0,576	0,492	0,126	0,197
$R_{11}$	0,168	0,222	–0,287	–0,577	0,618	–0,109	0,128	–0,017	0,071
$R_{12}$	0,052	0,207	–0,454	–0,560	0,544	–0,047	0,080	–0,145	0,121
$R_{13}$	0,675	0,480	–0,344	0,003	–0,179	–0,148	–0,171	0,220	0,009
$R_{14}$	0,651	0,489	–0,254	0,017	–0,263	–0,136	–0,202	0,238	0,128

<sup>2</sup>Статистический бюллетень / Нац. банк Респ. Беларусь. Минск, 2017. № 12. 262 с. ; Статистический бюллетень / Нац. банк Респ. Беларусь. Минск, 2019. № 12. 255 с. ; Статистический бюллетень / Нац. банк Респ. Беларусь. Минск, 2021. № 12. 276 с. ; Основные тенденции в экономике и денежно-кредитной сфере Республики Беларусь. Аналитическое обозрение / Нац. банк Респ. Беларусь. Минск, 2017. № 12. 56 с. ; Основные тенденции в экономике и денежно-кредитной сфере Республики Беларусь. Аналитическое обозрение / Нац. банк Респ. Беларусь. Минск, 2019. № 12. 51 с. ; Основные тенденции в экономике и денежно-кредитной сфере Республики Беларусь. Аналитическое обозрение / Нац. банк Респ. Беларусь. Минск, 2021. № 12. 49 с.

Показатели	Главные целостности								
	$I_1$	$I_2$	$I_3$	$I_4$	$I_5$	$I_6$	$I_7$	$I_8$	$I_9$
$R_{15}$	0,661	0,569	-0,203	0,012	-0,237	-0,108	0,050	0,005	-0,037
$R_{16}$	0,822	0,367	0,201	0,054	0,043	0,143	0,124	-0,188	-0,069
$R_{17}$	0,814	0,236	0,377	0,019	-0,057	0,124	0,067	-0,195	-0,140
$R_{18}$	0,784	0,393	-0,246	0,047	-0,171	0,006	0,152	-0,216	-0,134
$R_{19}$	0,524	-0,436	0,603	-0,271	0,099	0,019	-0,035	-0,021	0,095
$R_{20}$	0,585	-0,197	0,642	-0,095	0,068	0,189	-0,022	0,171	0,028
$R_{21}$	0,562	-0,269	0,711	-0,123	0,165	0,029	-0,017	0,063	0,121

Среднюю тесноту внутренних связей целостности характеризует коэффициент целостности  $\gamma_j$ :

$$\gamma_j = \sqrt{\frac{\sum_{i=1}^{k_j} a_{ij}^2}{k_j}},$$

где  $k_j$  – число исходных показателей, относящихся к  $j$ -й целостности;  $a_{ij}$  – коэффициент тесноты связей между  $i$ -м показателем и  $j$ -й целостностью [29].

Целостность финансового рынка и внешней среды представляет собой неоднородную структуру, поскольку коэффициенты целостности основных сегментов рынка и внешней среды различны (рис. 3). Семь целостностей ( $I_1, I_2, I_3, I_4, I_6, I_8, I_9$ ) имеют почти в 2 раза более высокие значения коэффициентов целостности по сравнению с коэффициентами целостности прочих целостностей ( $I_{10}, I_{11}, \dots, I_{21}$ ). Поэтому первые семь целостностей названы главными, а остальные – прочими. К главным целостностям отнесены также целостности  $I_5$  и  $I_7$ , поскольку в состав их исходных показателей входят те же исходные показатели, что и для целостностей  $I_4$  и  $I_6$ . Это значит, что целостности  $I_4$  и  $I_6$  имеют по две степени свободы.

Состав главных целостностей финансового рынка и внешней среды формируется на основе анализа спектра собственных форм, содержащихся в столбцах матрицы целостных образов (см. табл. 1), которые представлены в графической форме (см. рис. 3). К главной целостности относятся исходные показатели, имеющие наибольшие абсолютные значения собственной формы целостности и отличающиеся друг от друга в диапазоне  $\pm 10\%$  (на рис. 4 приведены их числовые значения). Название целостности формируется на основе тех показателей (или их большинства), которые относятся к данной целостности.

Целостность  $I_1$  идентифицирует рынок банковских вкладов (депозитов). Первая собственная форма целостности показывает, что основной вклад в формирование целостности  $I_1$  вносят исходные показатели  $R_{16}, R_{17}$  и  $R_{18}$ , для которых значения собственных форм целостностей соответственно равны 0,822; 0,814 и 0,784 (см. рис. 4). Аналогичным образом формируются остальные целостности (рис. 5): целостность  $I_2$  соответствует макроэкономической среде рынка (показатели  $R_4, R_5, R_7, R_8, R_{15}$ ), целостность  $I_3$  идентифицирует рынок банковских кредитов (показатели  $R_{19}, R_{20}, R_{21}$ ), целостность  $I_4$  обозначает макроэкономическую среду и сегмент валютного рынка, на котором осуществляются сделки с евро и долларами США (показатели  $R_1, R_3, R_6, R_{11}, R_{12}$ ), целостность  $I_5$  идентифицирует вторую степень свободы сегмента валютного рынка евро и долларов США (показатели  $R_{11}, R_{12}$ ), целостность  $I_6$  соответствует макроэкономической среде и сегменту валютного рынка, на котором осуществляются сделки с российскими рублями (показатели  $R_2, R_{10}$ ), целостность  $I_7$  идентифицирует вторую степень свободы рынка российских рублей (показатели  $R_2, R_{10}$ ), целостность  $I_8$  обозначает макроэкономическую среду и рынок межбанковских кредитов (показатели  $R_3, R_{13}, R_{14}$ ), целостность  $I_9$  идентифицирует сегмент макроэкономической среды (показатели  $R_3, R_9$ ).

Таким образом, результаты спектрального анализа целостности финансового рынка и внешней среды позволяют разбить все целостности на три группы: целостности внешней среды, целостности финансового рынка и внешней среды, целостности финансового рынка.

Входными данными для обучения нейронной сети являются ряды данных интегральных показателей целостности финансового рынка, которые рассчитываются по формуле (2) (рис. 6). За длину скользящего окна приняты три периода продолжительностью 1 мес. каждый с шагом 1 мес. Размерность обучающей выборки равна числу месяцев в рассматриваемом пятилетнем периоде минус размер скользящего окна и период прогнозирования длительностью 3 мес. с шагом 1 мес. Для исследуемого периода, равного пяти годам, размерность обучающей выборки составляет  $60 - 3 - 3 = 54$ .

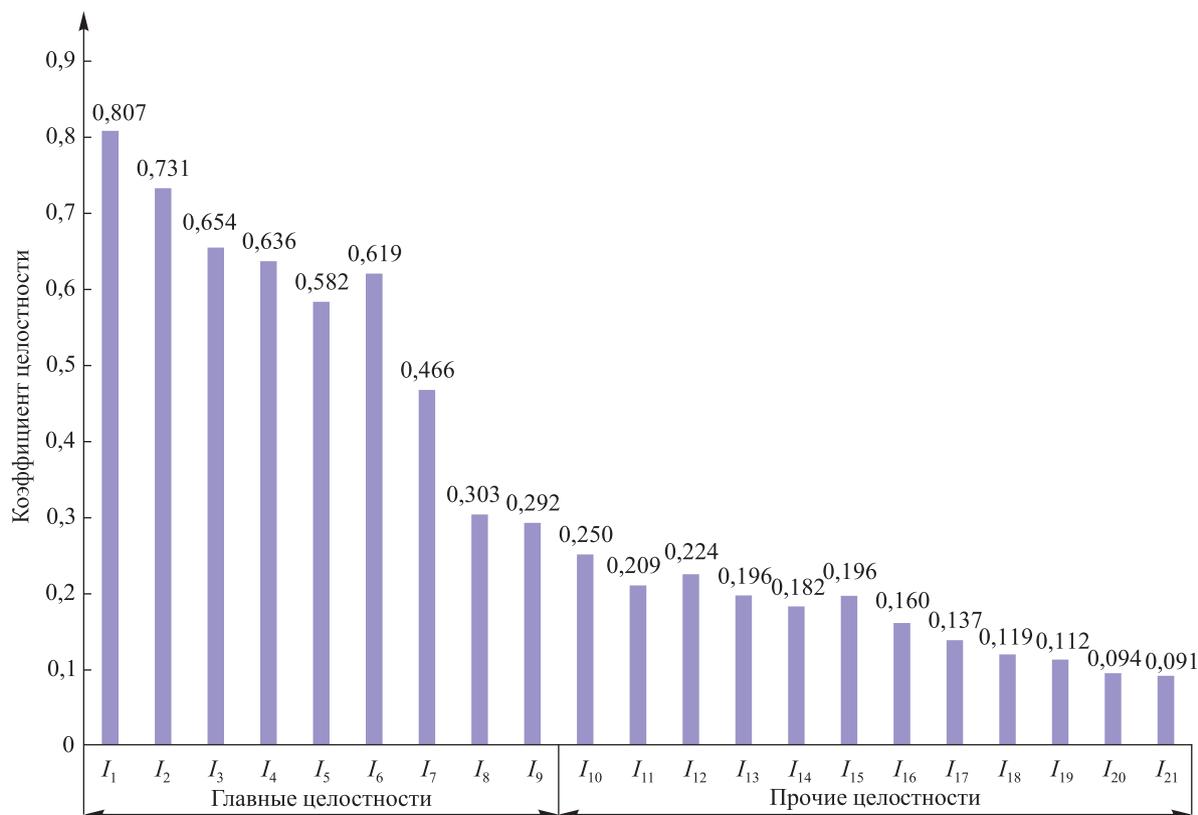


Рис. 3. Коэффициенты целостности финансового рынка и внешней среды  
 Fig. 3. Coefficients of integrity of the financial market and the external environment

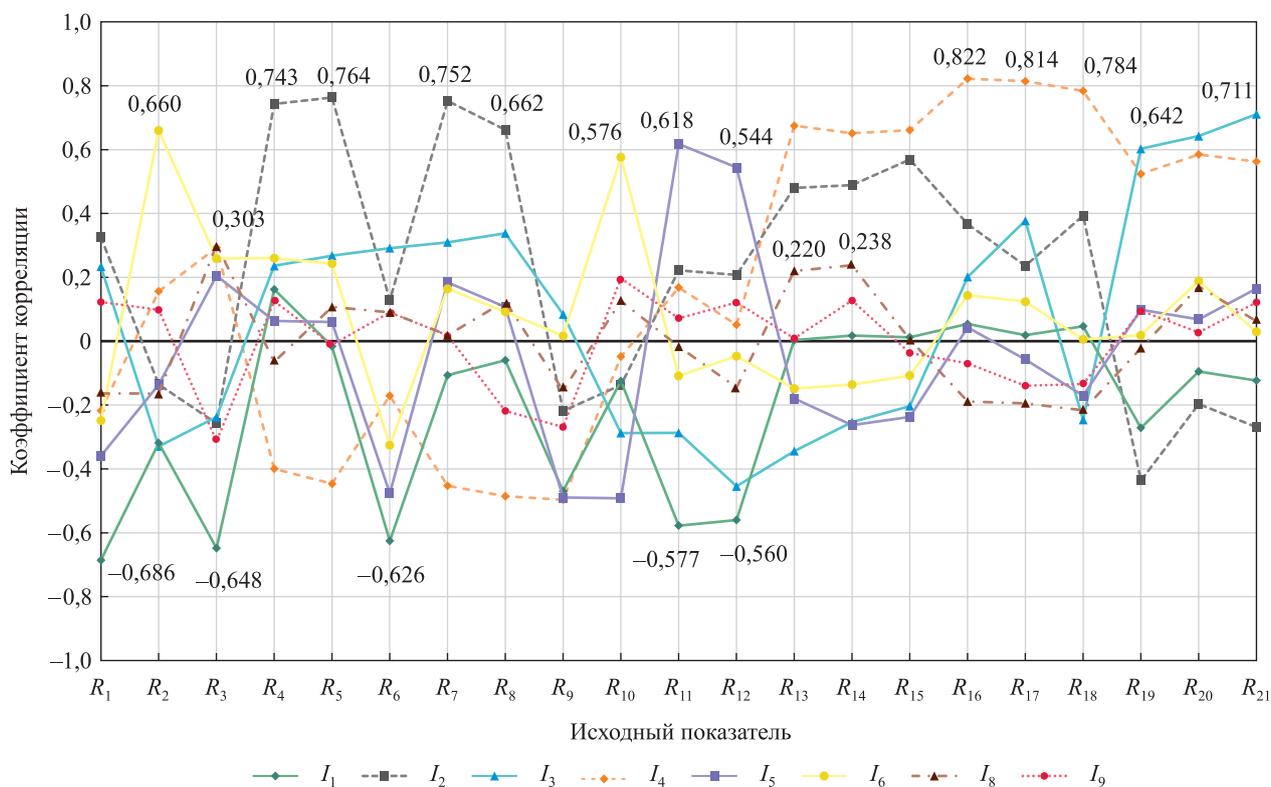


Рис. 4. Собственные формы главных целостностей финансового рынка и внешней среды  
 Fig. 4. Eigenforms of the main integrity of the financial market and the external environment

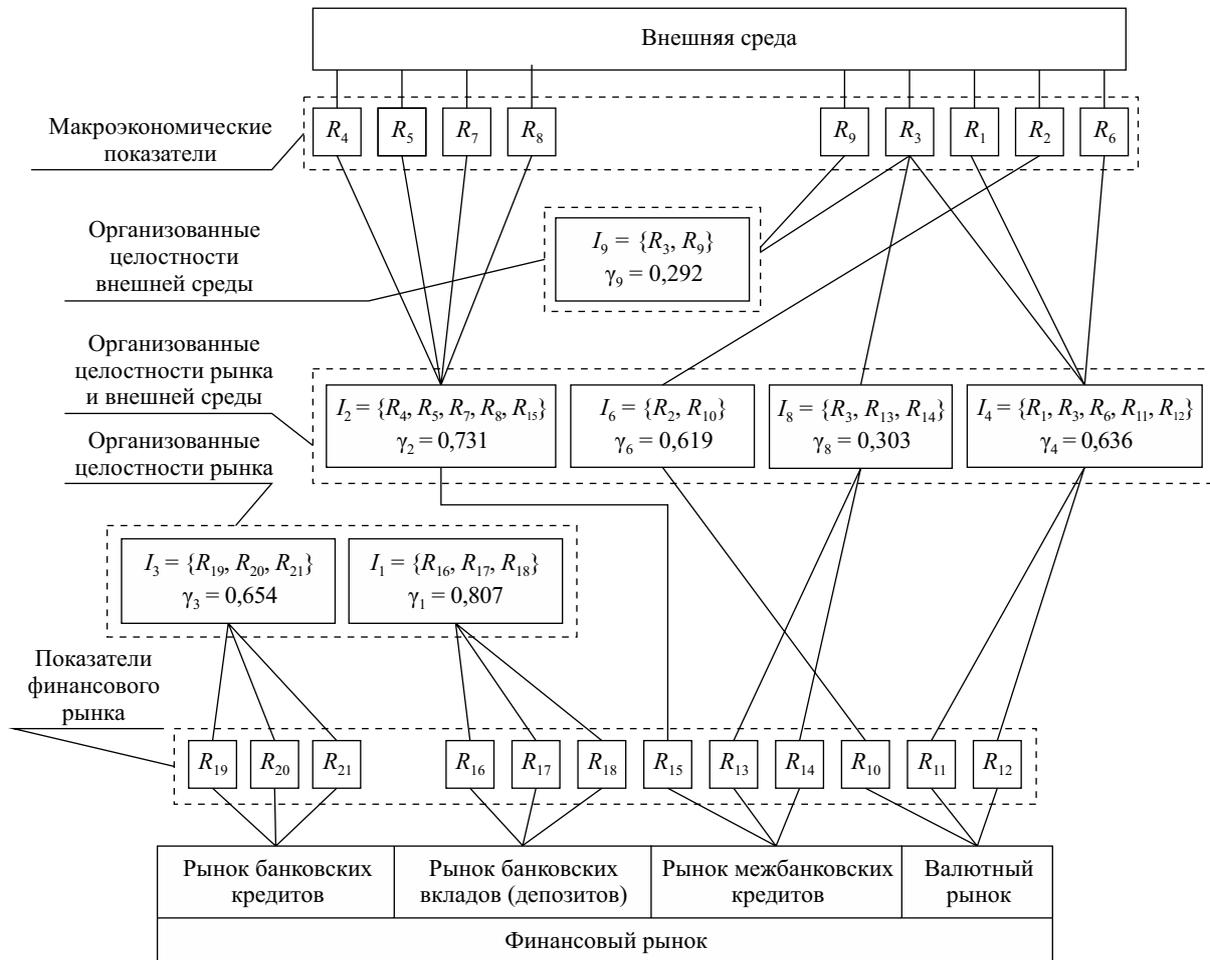


Рис. 5. Состав целостностей финансового рынка и внешней среды

Fig. 5. The composition of the integrity of the financial market and the external environment

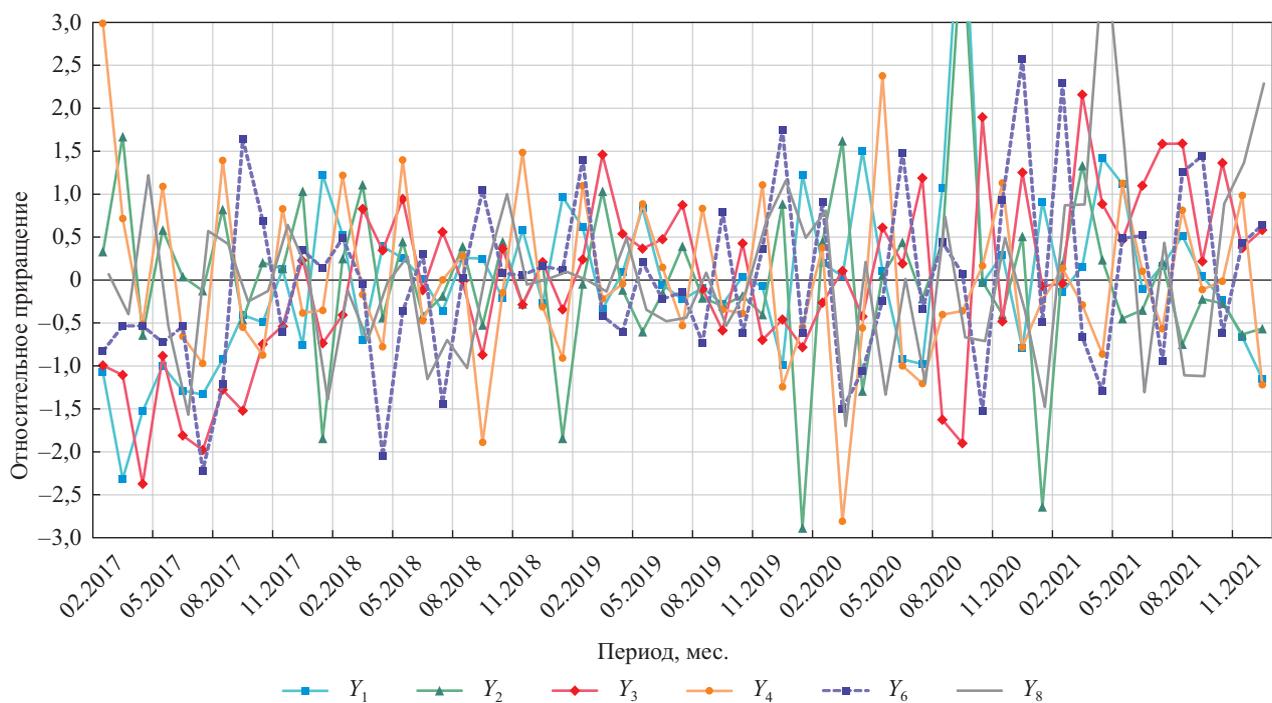


Рис. 6. Динамика интегральных показателей целостности

Fig. 6. Dynamics of integral integrity indicators

Архитектура нейронной сети содержала 27 входных нейронов, два скрытых слоя, которые имели по 27 нейронов в каждом слое, и 3 выходных нейрона. При этом количество выходных нейронов равнялось горизонту прогнозирования. Для нейронов скрытых слоев была задействована функция активации гиперболического тангенса, а для нейронов выходного слоя применялась линейная функция активации [16]. Для обучения нейронной сети использовался алгоритм обратного распространения ошибки [22]. Критерием прекращения обучения нейронной сети являлась максимально допустимая сумма квадратов ошибки обучения. Перед началом обучения весовые коэффициенты нейронной сети инициализировались случайным образом в диапазоне от  $-0,1$  до  $0,1$ . Шаг обучения нейронной сети равнялся 1 мес.

На рис. 7 показаны результаты гибридного нейросетевого ретропрогнозирования, т. е. прогнозирования для прошлых периодов, и исходный ряд процентной ставки рынка банковских вкладов (депозитов) за период с 01.02.2017 по 01.02.2022. Кроме того, реальный прогноз осуществлялся на январь – март 2022 г. Важно подчеркнуть, что, хотя на вход гибридной нейросетевой модели подавались масштабированные и стандартизованные ряды данных исходных показателей, результат прогнозирования получен в исходном масштабе. Во-первых, это значит, что при масштабировании и стандартизации исходных рядов данных, используемых для построения модели организованной целостности рынка, не было допущено принципиальных ошибок и не произошло потеря точности или искажение исходной информации.

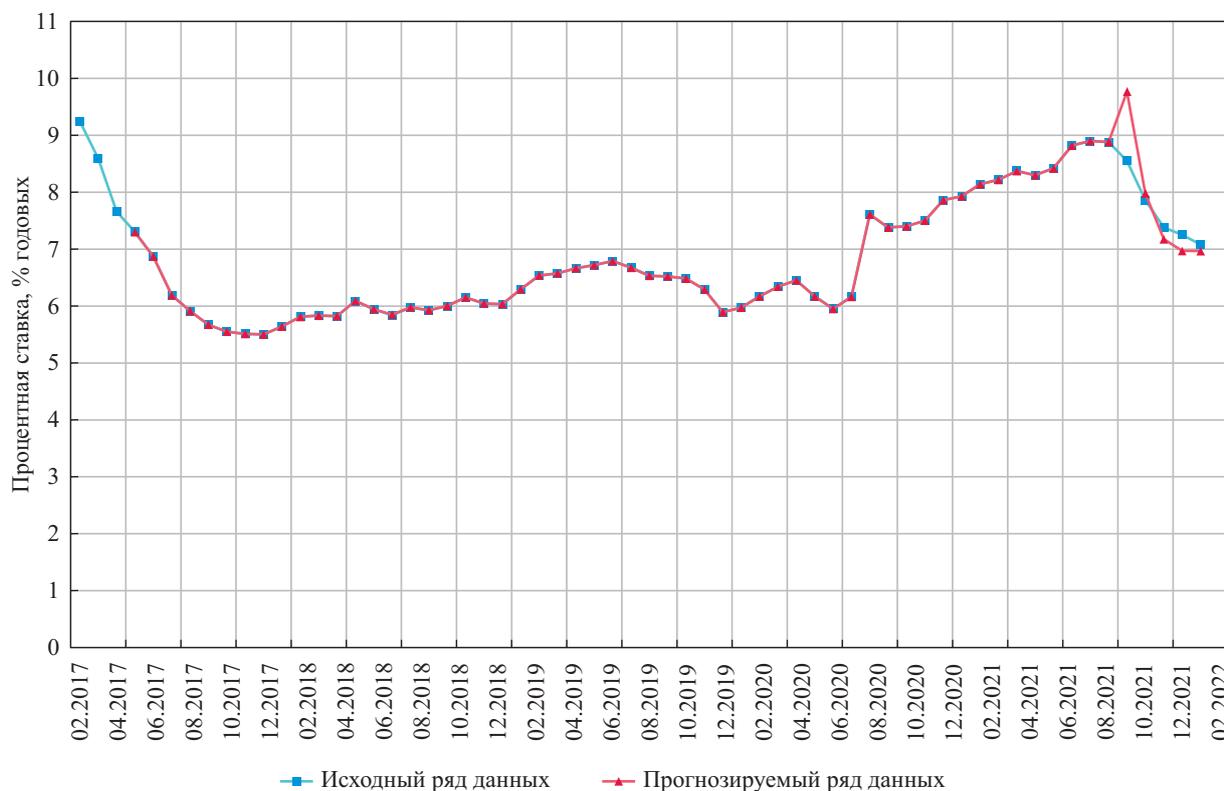


Рис. 7. Динамика процентной ставки рынка банковских вкладов (депозитов)

Fig. 7. Dynamics of the interest rate of the bank deposits market

Во-вторых, нейронная сеть обладает способностью восстанавливать масштабированные и стандартизованные ряды данных в процессе обучения. Это возможно потому, что на выход нейронной сети подаются образы, сформированные на основе рядов данных в исходном масштабе, и именно относительно этих рядов данных рассчитывается ошибка нейронной сети, которая согласно алгоритму обратного распространения ошибки распространяется в обратном направлении (от выхода нейронной сети к ее входу), модифицируя весовые коэффициенты синаптических связей таким образом, что исходные ряды ремасштабируются и дестандартизируются.

### Оценка качества прогноза

Результаты прогнозирования показателей финансового рынка свидетельствуют о том, что гибридная нейросетевая модель хорошо аппроксимирует эмпирические данные, сохраняя при этом обобщающую способность, что позволяет использовать ее для прогнозирования поведения финансового рынка. Все

исходные показатели финансового рынка ( $R_{10}, R_{11}, \dots, R_{21}$ ) имеют высокие значения коэффициентов детерминации, находящихся в диапазоне от 0,887 до 1, и низкие среднеквадратичные отклонения ошибок, которые намного ниже абсолютных значений соответствующих исходных показателей (табл. 3).

Таблица 3

Параметры качества прогнозирования показателей финансового рынка в 2017–2021 гг.

Table 3

Quality parameters of forecasting financial market indicators in 2017–2021

Параметр качества прогноза	Прогнозируемые показатели											
	$R_{10}$	$R_{11}$	$R_{12}$	$R_{13}$	$R_{14}$	$R_{15}$	$R_{16}$	$R_{17}$	$R_{18}$	$R_{19}$	$R_{20}$	$R_{21}$
Коэффициент детерминации ( $R^2$ )	0,980	0,984	1,000	0,990	0,981	0,985	0,973	0,982	0,887	0,836	0,915	0,857
Среднеквадратичное отклонение ошибки	0,016	0,031	0,006	0,297	0,660	0,402	0,163	0,263	0,827	0,366	0,368	0,382
Суммарный квадрат ошибок	0,007	0,027	0,001	2,477	12,214	4,532	0,745	1,942	19,173	3,752	3,797	4,077
Ошибка прогноза на 2 мес. 2022 г., %	2,1	3,4	0,7	25,6	–	17,7	3,9	3,2	35,4	14,1	17,7	14,3

Для первых двух месяцев 2022 г. ошибки прогноза большинства исходных показателей находятся на приемлемом для практического использования уровне. При этом следует иметь в виду, что для прогнозирования показателей рынка выбран самый неблагоприятный период, связанный с внешним фактором (начало специальной военной операции), который не был учтен при обучении нейронной сети. Наименьшую ошибку прогноза имеют показатели валютного рынка. Ошибки прогноза рынка банковских вкладов (депозитов) и рынка банковских кредитов находятся на удовлетворительном уровне. Наименьшая точность прогноза характерна для рынка межбанковских кредитов. Для показателей  $R_{13}$  и  $R_{15}$  относительная ошибка прогноза равна соответственно 25,6 и 17,7 %. Для показателя  $R_{14}$  ошибка прогноза не определялась, поскольку в этот период сделки не заключались и данные для оценки прогноза отсутствовали.

Сопоставляя между собой результаты прогнозирования всех сегментов финансового рынка, можно отметить, что рынок межбанковских кредитов подвержен наибольшему влиянию внешних факторов, поскольку под их воздействием он обладает наибольшей волатильностью, и, соответственно, является наименее предсказуемым.

Для оценки влияния нелинейного фактора модели на качество прогнозирования поведения рынка результаты гибридного нейросетевого прогнозирования сравнивались с результатами прогнозирования с помощью множественной линейной регрессии (табл. 4). Модель множественной линейной регрессии строилась методом наименьших квадратов между матрицами входных и выходных векторов нейросетевой модели. Качество прогнозирования с помощью множественной линейной регрессии существенно уступает качеству прогнозирования с помощью гибридной нейросетевой модели, поскольку коэффициент детерминации ряда данных, полученный с помощью множественной линейной регрессии, на 18,4 % меньше коэффициента детерминации ряда данных, рассчитанного с помощью гибридной нейросетевой модели, а среднеквадратичное отклонение ошибки почти в 3 раза выше, чем для гибридной нейросетевой модели. Таким образом, учет нелинейных эффектов в модели прогнозирования поведения рынка существенно повышает качество прогнозирования.

Таблица 4

Показатели качества прогнозирования процентной ставки ( $R_{16}$ ) в 2017–2021 гг.

Table 4

Indicators of the quality of forecasting the interest rate ( $R_{16}$ ) in 2017–2021

Модель	Коэффициент детерминации	Среднеквадратичное отклонение ошибки	Суммарный квадрат ошибок	Время обучения нейросети, с
Множественная линейная регрессия	0,799	0,442	5,470	0,005
Гибридная нейросетевая модель	0,979	0,145	0,585	0,635

## Заклучение

Таким образом, гибридизация моделей нейронной сети и организованной целостности рынка представляется вполне оправданной, поскольку эти модели органично дополняют друг друга. С одной стороны, модель организованной целостности рынка учитывает его неоднородную пространственно-временную структуру во взаимосвязи с внешней средой и включает в процесс прогнозирования модель измерения показателей целостности. С другой стороны, нейронная сеть позволяет учесть нелинейные эффекты, а также восстановить предварительно масштабированные и стандартизованные ряды данных и получить результат в исходном масштабе.

Эффект взаимодействия модели рынка как организованной целостности и модели нейронной сети, имеющей свойства и параметры, соответствующие модели организованной целостности рынка, позволяет уточнить параметры и упростить архитектуру нейронной сети, уменьшить время ее обучения и повысить качество прогнозирования. Численные эксперименты позволили установить, что для прогнозирования поведения рынка как организованной целостности с помощью нейронных сетей последние должны соответствовать следующим требованиям:

- модель нейронной сети должна представлять собой нейронную сеть прямого распространения с двумя внутренними слоями и количеством нейронов в каждом внутреннем слое, равным размерности входного вектора;
- для одного прогнозируемого показателя число нейронов выходного слоя нейронной сети должно быть равным горизонту прогнозирования;
- для нейронов внутренних слоев необходимо использовать функцию активации гиперболического тангенса, а для нейронов выходного слоя – линейную функцию активации;
- эффективным алгоритмом обучения нейронной сети должен выступать алгоритм обратного распространения ошибки.

## Библиографические ссылки

1. Сафронова В. Прогнозирование и моделирование в социальной работе. Москва: Академия; 2002. 192 с.
2. Kin Keung Lai, Lean Yu, Shouyang Wang, Wei Huang. Hybridising exponential smoothing and neural network for financial time series prediction. In: Alexandrov V, van Albada GD, Sloot PMA, Dongarra J, editors. *Computational science – 2006. Proceedings of the 6<sup>th</sup> International conference; 2006 May 28–30; London, UK. Part 4*. Berlin: Springer; 2006. p. 493–500.
3. Lean Yu, Shouyang Wang, Kin Keung Lai. *Foreign-exchange-rate forecasting with artificial neural networks*. Berlin: Springer; 2007. 323 p.
4. Ince H, Trafalis T. A hybrid model for exchange rate prediction. *Decision Support Systems*. 2006;42(2):1054–1062. DOI: 10.1016/j.dss.2005.09.001.
5. Zhang GP. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003;50:159–175. DOI: 10.1016/S0925-2312(01)00702-0.
6. Fang-Mei Tseng, Hsiao-Cheng Yu, Gwo-Hsiung Tzeng. Combining neural network model with seasonal time series ARIMA model. *Technological, Forecasting and Social Change*. 2002;69(1):71–87. DOI: 10.1016/S0040-1625(01)00121-4.
7. Lean Yu, Shouyang Wang, Kin Keung Lai. A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates. *Computers & Operations Research*. 2005;32(10):2523–2541. DOI: 10.1016/j.cor.2004.06.024.
8. Lean Yu, Kin Keung Lai, Shouyang Wang. Designing a hybrid AI system as a Forex trading decision support tool. In: IEEE Computer Society. *Proceedings of IEEE International conference on tools with artificial intelligence; 2005 November 14–16; Hong-Cong, China*. Los Alamitos: IEEE Computer Society; 2005. p. 89–93.
9. Youngohc Yoon, Tor Guimaraes, George Swales. Integration artificial neural networks with rulebased expert system. *Decision Support System*. 1994;11(5):497–507. DOI: 10.1016/0167-9236(94)90021-3.
10. Luxhoj JT, Riis JO, Stensballe B. A hybrid econometric-neural network modeling approach for sales forecasting. *International Journal of Production Economics*. 1996;43(2/3):175–192. DOI: 10.1016/0925-5273(96)00039-4.
11. Китова ОВ, Дьяконова ЛП, Китов ВА, Савинова ВМ. Применение нейронных сетей для прогнозирования социально-экономических временных рядов. *Российский экономический вестник*. 2020;3(5):188–201.
12. Denton JW. How good are neural networks for causal forecasting? *Journal of Business Forecasting*. 1995;14(2):17–20.
13. Ежов АА, Шумский СА. *Нейрокомпьютинг и его применения в экономике и бизнесе*. Москва: МИФИ; 1998. 222 с.
14. Бельзецкий А. Рынок как организованная целостность. *Вестник Института экономики НАН Беларуси*. 2022;5:83–97.
15. Головкин ВА, Краснопрошин ВВ. *Нейросетевые технологии обработки данных*. Минск: БГУ; 2017. 263 с.
16. Haykin S. *Neural networks. A comprehensive foundation*. London: Pearson; 2005. 864 p.
17. Golub G, Kahan W. Calculating the singular values and pseudoinverse of a matrix. *SIAM Journal on Numerical Analysis. Series B*. 1965;2(2):205–223.
18. Golub GH, Reinsch C. Singular value decomposition and least squares solutions. *Numerische Mathematik*. 1970;14:403–420.
19. Strang G. *Introduction to linear algebra*. Wellesley: Wellesley Cambridge Press; 2016. 586 p.
20. Zak D. *Programming with Microsoft Visual Basic 2015*. Boston: Cengage Learning; 2016. 914 p.
21. Newsome B. *Beginning Visual Basic 2015*. Indianapolis: John Wiley & Sons; 2015. 621 p.
22. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*. 1986;323:533–536.
23. Тихомиров НП, Дорохина ЕЮ. *Эконометрика*. Москва: Экзамен; 2003. 512 с.
24. Хацкевич ГА, Русилко ТВ. *Эконометрика*. Минск: РИВШ; 2021. 452 с.

25. Bartlett M. Tests of significance in factor analysis. *British Journal of Psychology*. 1950;3(2):77–85.
26. Wilks S. Certain generalisations in analysis of variance. *Biometrika*. 1932;24:471–494.
27. Cureton EE, D'Agostino RB. *Factor analysis: an applied approach*. New York: Psychology Press; 1993. 480 p.
28. Kaiser HF, Rice J. Little Jiffy, Mark IV. *Educational and Psychological Measurement*. 1974;34(1):111–117.
29. Бельзецкий А. *Маркетология: общая теория рынков*. Минск: Колорград; 2022. 475 с.

## References

1. Safronova V. *Prognozirovanie i modelirovanie v sotsial'noi rabote* [Forecasting and modeling in social work]. Moscow: Akademiya; 2002. 192 p. Russian.
2. Kin Keung Lai, Lean Yu, Shouyang Wang, Wei Huang. Hybridising exponential smoothing and neural network for financial time series prediction. In: Alexandrov V, van Albada GD, Sloot PMA, Dongarra J, editors. *Computational science – 2006. Proceedings of the 6<sup>th</sup> International conference; 2006 May 28–30; London, UK. Part 4*. Berlin: Springer; 2006. p. 493–500.
3. Lean Yu, Shouyang Wang, Kin Keung Lai. *Foreign-exchange-rate forecasting with artificial neural networks*. Berlin: Springer; 2007. 323 p.
4. Ince H, Trafalis T. A hybrid model for exchange rate prediction. *Decision Support Systems*. 2006;42(2):1054–1062. DOI: 10.1016/j.dss.2005.09.001.
5. Zhang GP. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003;50:159–175. DOI: 10.1016/S0925-2312(01)00702-0.
6. Fang-Mei Tseng, Hsiao-Cheng Yu, Gwo-Hsiung Tzeng. Combining neural network model with seasonal time series ARIMA model. *Technological, Forecasting and Social Change*. 2002;69(1):71–87. DOI: 10.1016/S0040-1625(01)00121-4.
7. Lean Yu, Shouyang Wang, Kin Keung Lai. A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates. *Computers & Operations Research*. 2005;32(10):2523–2541. DOI: 10.1016/j.cor.2004.06.024.
8. Lean Yu, Kin Keung Lai, Shouyang Wang. Designing a hybrid AI system as a Forex trading decision support tool. In: *IEEE Computer Society. Proceedings of IEEE International conference on tools with artificial intelligence; 2005 November 14–16; Hong-Cong, China*. Los Alamitos: IEEE Computer Society; 2005. p. 89–93.
9. Youngohc Yoon, Tor Guimaraes, George Swales. Integration artificial neural networks with rulebased expert system. *Decision Support System*. 1994;11(5):497–507. DOI: 10.1016/0167-9236(94)90021-3.
10. Luxhoj JT, Riis JO, Stensballe B. A hybrid econometric-neural network modeling approach for sales forecasting. *International Journal of Production Economics*. 1996;43(2/3):175–192. DOI: 10.1016/0925-5273(96)00039-4.
11. Kitova OV, Dyakonova LP, Kitov VA, Savinova VM. Application of neural networks for predicting socio-economic time series. *Russian Economic Bulletin*. 2020;3(5):188–201. Russian.
12. Denton JW. How good are neural networks for causal forecasting? *Journal of Business Forecasting*. 1995;14(2):17–20.
13. Ezhov AA, Shumskii SA. *Neirokomp'yuting i ego primeneniya v ekonomike i biznese* [Neurocomputing and its applications in economics and business]. Moscow: Moscow Engineering Physics Institute; 1998. 222 p. Russian.
14. Belzetsky A. The market as an organised integrity. *Bulletin of the Institute of Economics of NAS of Belarus*. 2022;5:83–97. Russian.
15. Golovko VA, Krasnoproshin VV. *Neirosetevye tekhnologii obrabotki dannyykh* [Neural network data processing technologies]. Minsk: Belarusian State University; 2017. 263 p. Russian.
16. Haykin S. *Neural networks. A comprehensive foundation*. London: Pearson; 2005. 864 p.
17. Golub G, Kahan W. Calculating the singular values and pseudoinverse of a matrix. *SIAM Journal on Numerical Analysis. Series B*. 1965;2(2):205–223.
18. Golub GH, Reinsch C. Singular value decomposition and least squares solutions. *Numerische Mathematik*. 1970;14:403–420.
19. Strang G. *Introduction to linear algebra*. Wellesley: Wellesley Cambridge Press; 2016. 586 p.
20. Zak D. *Programming with Microsoft Visual Basic 2015*. Boston: Cengage Learning; 2016. 914 p.
21. Newsome B. *Beginning Visual Basic 2015*. Indianapolis: John Wiley & Sons; 2015. 621 p.
22. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*. 1986;323:533–536.
23. Tihomirov NP, Dorohina EYu. *Ekonometrika* [Econometrics]. Moscow: Ekzamen; 2003. 512 p. Russian.
24. Hatskevich GA, Rusilko TV. *Ekonometrika* [Econometrics]. Minsk: National Institute for Higher Education; 2021. 452 p. Russian.
25. Bartlett M. Tests of significance in factor analysis. *British Journal of Psychology*. 1950;3(2):77–85.
26. Wilks S. Certain generalisations in analysis of variance. *Biometrika*. 1932;24:471–494.
27. Cureton EE, D'Agostino RB. *Factor analysis: an applied approach*. New York: Psychology Press; 1993. 480 p.
28. Kaiser HF, Rice J. Little Jiffy, Mark IV. *Educational and Psychological Measurement*. 1974;34(1):111–117.
29. Belzetsky A. *Marketologiya: obshchaya teoriya rynkov* [Marketology: general theory of markets]. Minsk: Kolorgrad; 2022. 475 p. Russian.

Статья поступила в редакцию 29.01.2023.  
Received by editorial board 29.01.2023.