

Прогнозирование агропродовольственных экономических систем с использованием искусственных нейронных сетей

А. А. Дубовицкий[✉], Э. А. Климентова

Мичуринский государственный аграрный университет, Мичуринск, Россия

[✉]E-mail: daa1-408@yandex.ru

Аннотация. Цель – обоснование применимости использования искусственных нейронных сетей к прогнозированию агропродовольственных экономических систем. **Методы.** Исследование основано на использовании элементов интерпретативного метода в сочетании генетического, структурного, функционального, комплексного, системного и эмпирического подходов. **Научная новизна** заключается в систематизации алгоритмов реализации искусственных нейронных сетей и обосновании их применимости для прогнозирования агропродовольственных экономических систем, разработке алгоритма и архитектуры построения нейронной сети на основе множественных данных о рынках сельскохозяйственной продукции, обосновании направлений совершенствования информационной инфраструктуры на уровне фирмы. **Результаты.** Авторами систематизированы интуитивные и формализованные методы прогнозирования, обосновано в этой системе место методов, построенных на машинном обучении. Подробно рассмотрены преимущества и недостатки использования искусственных нейронных сетей для прогнозирования агропродовольственных экономических систем, обоснована целесообразность их использования с точки зрения соответствия принципам прогнозирования. Анализ основных видов искусственных нейронных сетей позволил сделать вывод, что наиболее перспективными для реализации задач прогнозирования являются рекуррентные нейронные сети с алгоритмом обратного распространения (LSTM и GRU). Сформулированы основные цели построения моделей на основе нейронных сетей для использования в прогнозировании экономических систем, разработаны базовые положения последовательности и методики развертывания нейронных сетей в процессе прогнозирования на агропродовольственном рынке, ключевые элементы организации процесса прогнозирования в отдельных экономических субъектах, рассмотрены практические аспекты возможности использования математического алгоритма для моделирования агропродовольственных систем, а также условия совершенствования информационной инфраструктуры на уровне фирмы в целях обеспечения доступности источников данных, и технологий их обработки.

Ключевые слова: искусственный интеллект, машинное обучение, нейронные сети, сельское хозяйство, агропродовольственный рынок, прогнозирование, методология, методы

Благодарности. Авторы выражают благодарность М. А. Рогову за содействие в исследовании и техническую поддержку в проведении экспериментального тестирования модели машинного обучения.

Для цитирования: Дубовицкий А. А., Климентова Э. А. Прогнозирование агропродовольственных экономических систем с использованием искусственных нейронных сетей // Аграрный вестник Урала. 2024. Т. 24, № 08. С. 1093–1105. <https://doi.org/10.32417/1997-4868-2024-24-08-1093-1105>.

Дата поступления статьи: 11.04.2024, **дата рецензирования:** 31.05.2024, **дата принятия:** 14.06.2024.

Forecasting of agri-food economic systems using artificial neural networks

A. A. Dubovitskiy✉, E. A. Klimentova

Michurinsk State Agrarian University, Michurinsk, Russia

✉E-mail: daa1-408@yandex.ru

ЭКОНОМИКА

Abstract. The purpose of the study was to substantiate the applicability of the use of artificial neural networks to the forecasting of agro-food economic systems. **Methods.** The research is based on the use of elements of the interpretative method in a combination of genetic, structural, functional, complex, systemic, and empirical approaches. **The scientific novelty** it consists in systematization of algorithms for the implementation of artificial neural networks and substantiation of their applicability for forecasting agro-food economic systems, development of an algorithm and architecture for building a neural network based on multiple data on agricultural markets, substantiation of directions for improving information infrastructure at the firm level. **Results.** The authors systematized intuitive and formalized forecasting methods, justified the place of methods based on machine learning in this system. The advantages and disadvantages of using artificial neural networks for forecasting agri-food economic systems are considered in detail, the expediency of their use from the point of view of compliance with the principles of forecasting is justified. The analysis of the main types of artificial neural networks allowed us to conclude that the most promising for the implementation of forecasting tasks are competitive neural networks with a back propagation algorithm (LSTM and GRU). The main objectives of building models based on neural networks for use in forecasting economic systems are formulated, the basic provisions of the sequence and methods of deploying neural networks in the forecasting process in the agri-food market are developed, the key elements of the organization of the forecasting process in individual economic entities are considered, practical aspects of the possibility of using a mathematical algorithm for modeling agri-food systems are considered, as well as the conditions for improving the information infrastructure at the firm level in order to ensure the availability of data sources and technologies for their processing.

Keywords: artificial intelligence, machine learning, neural networks, agriculture, agri-food market, forecasting, principles and methods of forecasting

Acknowledgements. The authors express their gratitude to M. A. Rogov for his assistance in the research and technical support in conducting experimental testing of the machine learning model.

For citation: Dubovitskiy A. A., Klimentova E. A. Forecasting of agri-food economic systems using artificial neural networks. *Agrarian Bulletin of the Urals*. 2024; 24 (08): 1093–1105. <https://doi.org/10.32417/1997-4868-2024-24-08-1093-1105>. (In Russ.)

Date of paper submission: 11.04.2024, **date of review:** 31.05.2024, **date of acceptance:** 14.06.2024.

Постановка проблемы (Introduction)

За последние десятилетия в теории и методах прогнозирования произошли кардинальные изменения, существенным образом сказавшиеся на реформировании системы управления экономикой многих стран. Широко признано, что эти изменения основаны на распространении новых идей и подходов, одновременно являющихся частью более широкой общественной дискуссии о цифровой трансформации, экономическом процветании и устойчивом развитии. Одним из ключевых вопросов, который обсуждается, является применимость искусственного интеллекта (Artificial Intelligence – AI) в прогнозировании социально-экономических систем. Одни авторы утверждают, что для решения насущных и сложных вопросов прогнозирования

требуются соответствующие подходы к управлению, которые могут способствовать повышению надежности прогнозирования и, как следствие, обоснованности принятия решений [3; 5]. Другие указывают на непредсказуемость развития AI как на неконтролируемую площадку, из которой могут возникнуть риски, генерирующие новые угрозы для устойчивого развития [11], или подчеркивают необходимость критически относиться к предубеждениям технологического развития, порождающим обширную утопическую и антиутопическую риторику [15]. Хотя многие из этих утверждений оспариваются или критикуются, стремление к более широкому использованию AI становится все более активной тенденцией в прогнозировании.

Путей использования моделей машинного обучения достаточно много. На сегодняшний день достигнут огромный прогресс в понимании возможностей моделирования в различных областях знаний – от медицины до индустрии развлечений – путем построения искусственных нейронных сетей с использованием различных алгоритмов машинного обучения. В агропродовольственном секторе это оценка площади загрязненности сорными растениями, оценка и картирование однородности всходов, выявления сортовой принадлежности семян и многих других задач. Однако по исследованию вопросов прогнозирования с использованием искусственных нейронных сетей (Artificial Neural Networks – ANN) существует все еще ограниченное количество публикаций [5; 7; 9] и практически нет публикаций, посвященных методологическим аспектам организации прогнозирования на основе ANN в сельском хозяйстве.

Данная статья стала попыткой устранения отмеченных пробелов и направлена на систематизацию алгоритмов реализации искусственных нейронных сетей и обоснование их применимости к прогнозированию агропродовольственных экономических систем. Основное внимание в ней уделяется методологическим вопросам использования искусственного интеллекта для прогнозирования параметров агропродовольственных систем, реализуемых путем построения ANN с использованием различных алгоритмов машинного обучения.

Методология и методы исследования (Methods)

В процессе написания данной статьи авторы опирались на результаты российских и зарубежных научных исследований в области развития искусственных нейронных сетей, прогнозирования агропродовольственных экономических систем и управления отраслями агропромышленного комплекса. Данное исследование основано на использовании элементов интерпретативного метода в сочетании генетического, структурного, функционального, комплексного, системного и эмпирического подходов. В процессе работы над данной статьей авторы оперировали основными дефинициями данной тематики, получившим широкое распространение в научной среде и практике прогнозирования. Экспериментальное тестирование модели машинного обучения при решении задачи прогнозирования основано на использовании открытых данных Службы экономических исследований Министерства сельского хозяйства США, содержащих информацию о региональных социально-демографических и социально-экономических характеристиках населения, включая показатели доступности продовольствия и торговой инфраструктуры, распространенности домохозяйств с низким уровнем доходов, участия домохозяйств в программах государственной поддержки [8].

Результаты (Results)

1. Методологические аспекты прогнозирования агропродовольственных экономических систем

Прогнозирование представляет возможности для улучшения способностей человека принимать обоснованные решения. Прогнозирование параметров агропродовольственных экономических систем в качестве одной из составляющих управления материальными потоками может обеспечить получение информации, представляющей собой количественные и качественные характеристики процессов формирования, транспортировки, торговли и удовлетворения потребностей конечных потребителей в определенных товарах как на определенную дату, так и на перспективу. Основными показателями, характеризующими состояние агропродовольственного рынка, являются потребности в том или ином товаре, объем предложения этих товаров и цена, являющаяся результатом рыночного взаимодействия потребностей и предложения [6; 7].

Прогнозирование имеет очень важное значение для производителей продукции, посредников и продавцов товара при планировании продаж. В условиях развитой рыночной системы потребность выступает двигателем развития рынка, а предложение всегда стремится к его удовлетворению. Достоверный прогноз уровня рыночных цен является одним из основных индикаторов эффективности сбыта и выступает в качестве предела возможного расширения производства того или иного товара, а также предикторов расширения экспорта.

Прогнозирование должно способствовать повышению предсказуемости агропродовольственных систем, обеспечивая актуальность, определенность, точность прогноза, а также ряд стратегических требований, выдвигаемых отдельными субъектами агробизнеса. В силу объективной сложности данных требований, связанных в том числе с многообразием направлений применения, задач надежности и факторов, влияющих на его результаты, существуют различные подходы к реализации этих задач.

С точки зрения возможности верификации результатов прогнозирования в практике хозяйствования используются как интуитивные (эвристические), так и формализованные методы с более точным, математическим выражением прогноза. Интуитивные методы применяются преимущественно в ситуациях, когда необходим субъективный взгляд эксперта или экспертов на возможности решения той или иной проблемы.

В отличие от интуитивных формализованные методы принято использовать в случаях, когда требуются более точные количественные оценки с привязкой к срокам реализации прогноза. Подобные прогнозы могут быть реализованы с использованием различных методов экстраполяции и модели-

рования. Экстраполяция, как правило, строится на анализе одномерных временных рядов и применима к решению задач прогнозирования процессов в случаях, когда тенденции их развития сохраняются в долгосрочной перспективе. Методы прогнозирования, основанные на построении статистико-экономических и экономико-математических моделей, более сложные в использовании, но при этом позволяют обеспечить понимание характера взаимодействия различных элементов социально-экономических систем, отдельных процессов и явлений, выраженных многомерными временными рядами, что позволяет достичь высокого уровня определенности и интерпретируемости результатов.

При этом общим для всех традиционных формализованных методов прогнозирования является линейный характер генерирования результата. Однако в экономической литературе последних лет отмечается, что макроэкономические параметры сложных экономических систем являются нелинейными, и судить о них в рамках традиционных линейных подходов достаточно трудно [10]. Кроме того, в последние годы участились масштабные колебания национальных и мировых цен на продовольствие, которые несут неконтролируемые риски снижения эффективности и оказывают существенное влияние на социально-экономическое развитие сельского хозяйства во многих регионах и странах. Современная волатильность параметров экономических систем такова, что традиционные формализованные методы прогнозирования (прежде всего методы экстраполяции и статистико-экономические методы) перестают обеспечивать желаемый уровень надежности.

Новые возможности в прогнозировании агропродовольственных систем открываются с развитием современных цифровых технологий, связанных с использованием ANN. В публикациях многих авторов доказано, что модели на основе ANN способны значительно повысить точность прогнозирования

в условиях высокой экономической неопределенности и ограниченной доступности данных для анализа крупномасштабных систем [1; 14]. Кроме того, отмечается, что подобные методы выигрывают с точки зрения таких факторов анализа данных, как скорость обработки, производительность и объем обработки исходной информации [9].

2. Применимость моделей машинного обучения с использованием нейронной сети для прогнозирования агропродовольственных экономических систем

В общем виде искусственные нейронные сети представляют собой вычислительные системы, схожие по своей структуре с биологическими нейронными сетями. Основу ANN составляют соединения блоков, или модулей, называемых искусственными нейронами, каждый из которых может получать, обрабатывать и передавать сигнал другим нейронам. Упрощенно нейрон в такой сети представляет собой пороговую систему, которая получает входные сигналы от других нейронов, суммирует их и, если эта сумма превышает некий порог, генерирует выходной сигнал. Нейроны объединяются в слои, которые могут выполнять различные преобразования входных данных. Сигналы передаются от первого слоя (входного) к последнему (выходному) с многократным преобразованием (рис. 1).

Сеть с одним скрытым слоем представляет собой гибкий аппроксиматор функций, которые связывают входные данные с желаемыми выходными данными. Наиболее распространенный тип модуля вычисляет взвешенную сумму входных данных и нелинейно преобразует результат. Взвешенная сумма нескольких нелинейных импульсов дает качественно другую непрерывную функцию в выходном пространстве. Таким образом, скрытый слой линейно-нелинейных единиц позволяет аппроксимировать функции, сильно отличающиеся по форме.




Рис. 1. Нейронная сеть с прямой связью, тремя модулями и одним скрытым слоем
 Fig. 1. A neural network with direct communication, three modules and one hidden

Математическая модель сети в общем виде представляет собой вычисление алгебраической суммы исходных сигналов (точек) с учетом их значимости (веса) и свободного члена при оценке соответствия какому-то критерию по системе включен/выключен:

$$Y = \sum_{i=1}^N x_i w_i + b, \quad (1)$$

где x – входные сигналы;

w – значимость входных сигналов;

b – свободный член (bias neuron), значение которого фиксированное.

Параметры значимости (w) задают силу связи между нейронами. Подбираются они в процессе тестирования модели таким образом, чтобы ошибка обучения (error training) была минимальной ($\rightarrow 0$). Совокупность этих параметров составляет матрицу синаптических связей, которая медленно меняется в процессе машинного обучения, что и позволяет реализовать функцию долговременного хранения информации.

Функционально значение b используется для повышения степени свободы и соответствует нейрону смещения (склонности).

Существует возможность аппроксимировать любую непрерывную функцию с любым желаемым уровнем точности, допуская достаточное количество единиц в одном скрытом слое. Пороговая система активации нейрона может быть построена на основе сигмовидной функции, которая формирует возможности обучения сети с использованием градиентного спуска:

$$\sigma(x) = \frac{1}{1 + b^{-x}}, \quad (2)$$

где x – амплитуда входного сигнала, который получает нейрон от других нейронов;

σ – выходной сигнал нейрона.

Главным преимуществом данной функции является ее небинарный и нелинейный характер, что позволяет строить сеть из нескольких слоев. Когда мы переходим от одной входной области к другой, сеть будет плавно переходить между различными выходными значениями. Точность такой аппроксимации всегда можно повысить, используя большее количество скрытых слоев. Если нейронная сеть имеет более одного скрытого слоя, то она называется глубокой.

Существует несколько основных видов ANN в зависимости от того, как данные передаются от входного слоя к выходному. Нейронные сети с прямой связью (Feedforward Neural Network – FFNN) обрабатывают данные в одном направлении, от входного модуля к выходному модулю. Блоки могут быть собраны в сети во многих различных конфигурациях. Каждый модуль одного слоя связан с каждым модулем следующего слоя. Эти связи слоев не все равнозначны, потому что каждое соединение может иметь различный вес или силу. Обработка

информации в сети включает в себя ввод данных от входных блоков и проходит через сеть, перетекая с одного уровня на другой, пока не попадет к выходным блокам [17]. Примерами FFNN являются однослойный перцептрон (Single-Layer Perceptron – SLP) и многослойный перцептрон (Multilayer Perceptron – MLP), сети радиальных базисных функций (Radial Basis Functions – RBF) и машины опорных векторов (Support Vector Machines – SVM). FFNN применяются для решения двух категорий задач: управления динамическими системами и классических задач определения репрезентативного сходства.

Одной из наиболее распространенных глубоких NN является сверточная (Convolutional Neural Networks – CNN). CNN основаны на реализации функций суммирования и фильтрации, называемых свертками. CNN состоят из одного или более сверточных слоев, полностью соединенными между собой. CNN имеет несколько уровней, включая полносвязный слой, слой пула, сверточный и нелинейный слой. Через эти слои сети преобразуют визуально-пространственное представление изображения в семантическое представление его содержимого, последовательно уменьшая пространственную детализацию карт и увеличивая количество семантических измерений [12]. По сравнению с другими глубокими архитектурами сверточные нейронные сети показали превосходные результаты в обработке изображений и речевых приложениях. Данный вид ANN чаще всего используется для решения задач классификации изображений, поскольку скрытый слой может извлекать из них соответствующие признаки, полезные для распознавания и классификации.

Искусственные нейронные сети с алгоритмом обратного распространения (Feed-Backward Neural Network – FBNN) основаны на передаче информации не только на следующий слой, но и на следующий временной шаг, возможно, с возвратом одновременно на другие модули и слои. FBNN способны к корректировке весовых коэффициентов признаков для компенсации каждой ошибки, обнаруженной во время обучения. Это позволяет сети повторно использовать свои вычислительные ресурсы с течением времени и выполнять более глубокую последовательность нелинейных преобразований. В результате FBNN могут выполнять более сложные вычисления, чем это было бы возможно при одном проходе с прямой связью через то же количество блоков и соединений [12].

Примером FBNN является рекуррентная нейронная сеть (Recurrent Neural Network – RNN). RNN относится к стандартному типу нейронной сети, где активность распространяется циклически, как в случае с мозгом (рис. 2).




Рис. 2. Модель рекуррентной нейронной сети с тремя модулями и одним скрытым слоем
 Fig. 2. A recurrent neural network model with three modules and one hidden layer

Именно это позволяет решать широкий круг задач, связанных с машинным обучением. Это один из самых современных алгоритмов глубокого обучения. Его преимущество основано на возможности сохранения информации при перемещении ее между слоями сети, что особенно важно для прогнозирования. В RNN информация проходит через внутренний цикл. Когда RNN вычисляет выходной слой, он учитывает не только предыдущий слой, но и слой перед ним.

В рекуррентных нейронных сетях невозможно выделить отдельные слои. Сигналы могут циркулировать по сети во всех направлениях, образуя сложную пространственно-временную структуру (pattern). Такие сети обладают колоссальными возможностями. Так, отмечается, что они могут моделировать любую динамическую систему [2].

Наиболее мощными алгоритмами RNN являются LSTM и GRU. Сеть с долговременной и кратковременной памятью (Long Short-Term Memory – LSTM) представляет собой сеть, которая строится на основе LSTM-модулей, обладающих способностью запоминать информацию как на короткие, так и на длинные промежутки времени [4; 16]. Основана данная возможность на отсутствии функции активации внутри своих рекуррентных компонентов. Реализация функции обучения происходит посредством достаточно интеллектуального обновления памяти в каждый момент времени. Для этого используется механизм формирования выхода (Gating Mechanism) с «памятью выхода», «сохранением выхода» и «фокусировкой выхода», с помощью которых сеть определяет, какие элементы информации необходимо забыть, какие добавить, а на каких необходимо сфокусировать внимание. Наличие функции памяти и механизма фильтрации информации являются важными преимуществами LSTM, а недостатком – слабо реализуемый принцип обрат-

ной связи. Этот недостаток устраняется в процессе построения сети на основе управляемых рекуррентных блоков (Gated Recurrent Units – GRU) с алгоритмом обратного распространения, используемого при обучении для прогнозирования недостающих точек в совокупности данных [13]. Архитектура GRU не предусматривает наличия явного модуля памяти за счет чего количество слоев уменьшается. При этом сеть достаточно проста и представлена двумя рекуррентными блоками, разворачивающимися в противоположных направлениях.

Сами по себе математические алгоритмы сформированной нейронной сети ANN изначально не несут сколько-нибудь важных практических решений. Использование построенной сети для моделирования агропродовольственных систем и прогнозирования их изменения возможно в результате обучения сети для лучшего решения задачи с учетом выборочных наблюдений. Обучение включает в себя настройку весов (и необязательных пороговых значений) сети для повышения точности результата.

Основная концепция машинного обучения заключается не в изучении уровней событий (абстракции), а в повышении качества обработки данных, в результате чего становится возможным понимание поведения сложных экономических систем на основе анализа необработанных данных. Машинное обучение позволяет реализовать функцию прогнозирования в ANN на основе оптимизации модели, которая является математически обобщенным представлением самих данных, позволяющим спрогнозировать соответствующий ответ.

Обычные методы машинного обучения делятся на две группы: контролируемые и неконтролируемые. Категория обучения с подкреплением позволяет системе учиться посредством взаимодействия с человеком и наблюдения за результатами этого взаимодействия. Эта группа методов обучения ис-

кусственных нейронных сетей применима к FFNN, в том числе SLP, MLP и SVM, а также часто к сетям SVM. Неконтролируемые методы (k-means, максимизация ожидания, автоэнкодеры и т. д.) применимы для обучения рекуррентных сетей, в том числе LSTM и GRU.

3. Этапы прогнозирования агропродовольственных экономических систем с использованием алгоритма машинного обучения

В процессе прогнозирования формируется размерность входных переменных в количестве n , по числу выборок N . При этом задаются входные переменные как вектора $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ наблюдаемых значений при $i = 1, 2, \dots, N$. Проводится предобработка данных, выстраивается архитектура нейронной сети, проводится обучение, анализируются полученные результаты.

При реализации модели основными целями выступают удовлетворительная точность прогнозирования, стремление к уменьшению времени вычислений и уменьшение потребности в памяти, достаточная интерпретируемость. Степень достижения поставленных целей является критерием качества построенной модели.

Ниже приведены конкретные этапы прогнозирования на агропродовольственном рынке на примере цен с использованием алгоритма машинного обучения.

Шаг 1. Получить доступ к источнику данных.

Шаг 2. Обеспечить сбор данных, отражающих характеристики, которые могут быть прямо или косвенно связаны с прогнозируемым параметром (ценой).

Шаг 3. Провести предобработку данных, поиск аномалий и снижение размерности.

Шаг 4. Сформировать базу данных обучения (N_t) и прогнозирования (N_p).

Шаг 5. Сформировать архитектуру нейронной сети.

Шаг 6. Выбрать функцию активации скрытого нейрона и метод инициализации весов.

Шаг 7. Провести обучение нейронной сети.

Шаг 8. Компилировать результаты и сохранить их в базу данных.

Шаг 9. Обеспечить доступность и наглядность результатов работы алгоритма.

Длительность обучения модели и результаты выхода напрямую зависят от качества, количества и дифференциации данных на входе модели. Обучение модели должно проводиться регулярно, но не непрерывно, поскольку в противном случае возможно переобучение модели, что в дальнейшем негативно отразится на результатах прогнозирования. При развертывании сетей в целях снижения вероятности избыточного переобучения в нейронных сетях может быть использован алгоритм Dropout, а для повышения интерпретируемо-

сти – механизм Attention с методом оптимизации адаптивного обнаружения объектов предметной области – Skip-Layers.

4. Экспериментальное тестирование модели машинного обучения при решении задачи прогнозирования цен

На основе широкого перечня данных Службы экономических исследований, имеющих в открытом доступе, выбраны факторы, отражающие характеристики, которые могут быть прямо или косвенно связаны с ценой. Их общее количество составило 63 значения по 3200 населенным пунктам городского типа [7; 8].

Для предобработки данных, поиска аномалий и снижения размерности использовались методы Soft Ensemble из моделей AdaBoost, Logistic Regression, SVM. В результате удалось снизить размерность входного вектора до 10 признаков, которые можно считать наиболее значимыми (таблица 1).

Проведенная систематизация основных видов ANN с учетом их назначения, сравнительного анализа основных положительных и отрицательных сторон позволила выбрать оптимальную архитектуру нейронной сети для использования субъектами агробизнеса в целях прогнозирования параметров агропродовольственных экономических систем. Была сформирована гибридная ANN прогнозирования с использованием моделей GRU и LSTM. Такое сочетание позволяет максимизировать положительные стороны и минимизировать недостатки каждой из них. Предотвращение переобучения ставилось одним из приоритетов, для чего использовалась регуляризация elastic-net, повышенный Dropout.

В итоге получена структура сети на основе двух RNN:

- 1) Bi-directional GRU + Dropout;
- 2) LSTM + Dropout + Attention со skip-layers.

Интеграция двух результатов обеспечена посредством реализации слоя активации за счет функций Dense и Activation. Настройка параметров проводилась на модели Bayesian GridSearch.

Функция активации моделей – selu, метод инициализации веса – lecun_normal. Результаты прошли валидацию по методу Cross-validation.

Приемлемый результат получен в процессе обучения модели в течение 80 эпох (рис. 3).

Реализованный алгоритм позволил сформировать модель прогнозирования на агропродовольственном рынке с достаточно удовлетворительным результатом. Величина дисперсии данных, которая объясняется моделью, составила 87 % ($R^2 = 0,87$), что свидетельствует об успешном обнаружении искомых параметров с использованием ANN на агропродовольственном рынке и может считаться достаточно удовлетворительным результатом с учетом полученных данных.

Таблица 1

Переменные базы данных обучения и прогнозирования

База данных обучения (N_t)	
1. Количество в расчете на 1000 жителей	1.1. Продуктовых магазинов
	1.2. Супермаркетов
	1.3. Круглосуточных магазинов
	1.4. Ресторанов быстрого питания
2. Доля в общей численности, %	2.1. Участников программы студенческих обедов
	2.2. Участников программы школьных завтраков
	2.3. Участников летней программы общественного питания
3. Число фермерских рынков – участников программ помощи семей с низким доходом, ед.	3.1. Программа дополнительной помощи в области питания (SNAP)
	3.2. Специальная программа дополнительного питания для женщин, младенцев и детей (WIC)
База данных прогнозирования (N_p)	
4. Параметры функционирования агропродовольственного рынка	4.1. Потребительские цены на рынке молока

Источник: составлено авторами на основе данных [8].

Table 1

Training and prediction database variables

Training database (N_t)	
1. Number per 1000 inhabitants	1.1. Grocery stores
	1.2. Supermarkets
	1.3. Convenience stores
	1.4. Fast food restaurants
2. Share in the total number, %	2.1. Student Lunch Program Participants
	2.2. School Breakfast Program Participants
	2.3. Summer Catering Program Participants
3. The number of farmers' markets participating in low-income family assistance programs, units	3.1. Supplemental Nutrition Assistance Program (SNAP)
	3.2. Special Supplemental Nutrition Program for Women, Infants, and Children (WIC)
Forecasting database (N_p)	
4. Parameters of the functioning of the agri-food market	4.1. Consumer prices on the milk market

Source: compiled by the authors according [8].

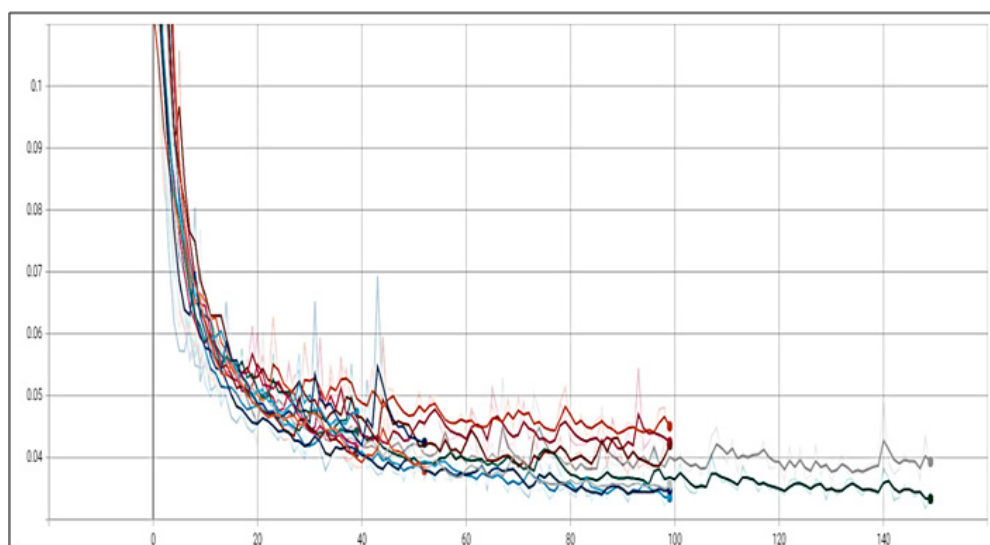


Рис. 3. График кривой обучения в зависимости от количества эпох

Источник: составлено авторами с использованием данных [7, 8]

Fig. 3. Graph of the learning curve depending on the number of epochs

Source: compiled by the authors using data [7, 8]

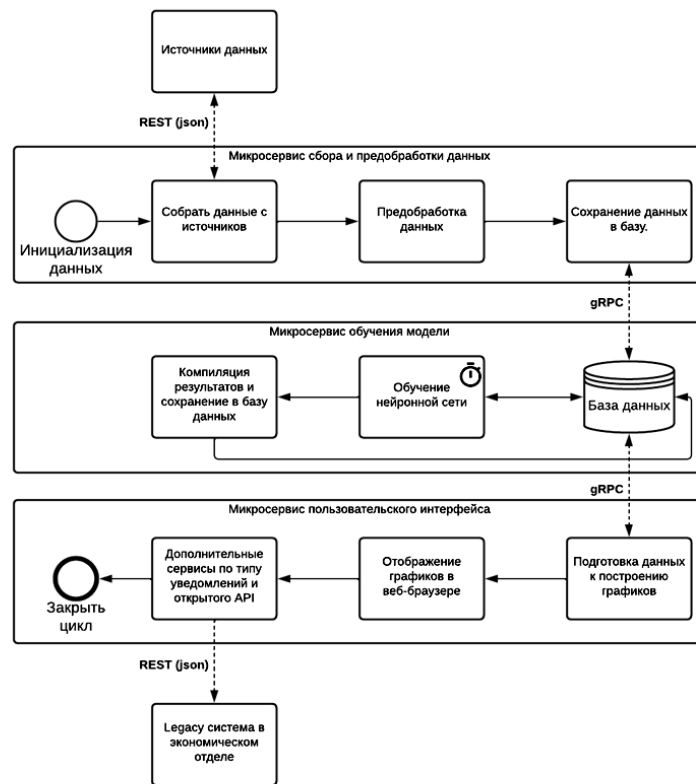


Рис. 4. BPMN-схема построения информационной инфраструктуры на уровне субъектов агробизнеса
Источник: по данным [7]

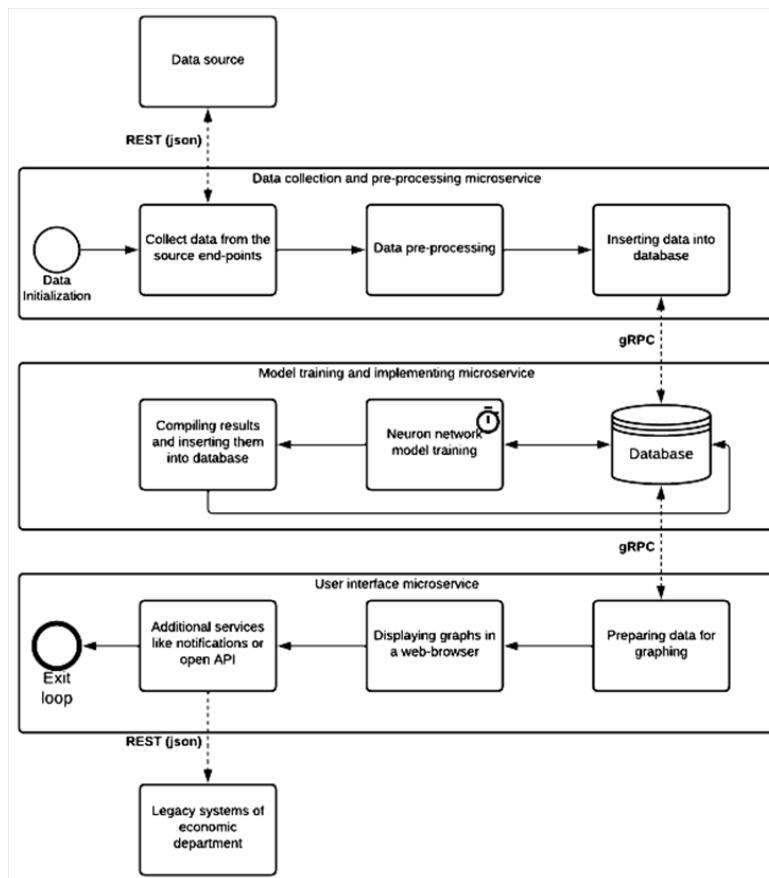


Fig. 4. BPMN scheme of building information infrastructure at the level of agribusiness entities
Source: according to [7]

Надо понимать, что после разработки модели результатом будет плохо читаемый обычным пользователем алгоритм на уровне кода. Пользоваться таким алгоритмом на практике сможет только хорошо обученный специалист – по большей части тот, кто и создал этот алгоритм. Для дальнейшего внедрения модели в систему прогнозирования сельскохозяйственной организации требуется создание информационной инфраструктуры на уровне самого предприятия.

5. Применимость ANN на уровне фирмы

Внедрение использования ANN в АПК обуславливает наличие больших объемов данных, генерируемых в данном направлении деятельности, которые должны оперативно систематизироваться, обрабатываться и представляться менеджменту компаний. В целях обеспечения практического использования полученного алгоритма разработанной модели в подразделениях экономических агентов агропродовольственной системы требуется обеспечить соответствующую инфраструктуру.

Создание модели и ее развертывание в организациях АПК может быть реализовано двумя путями. Первый предполагает привлечение команды компетентных специалистов, которая получив доступ к информационным ресурсам сможет развернуть платформу сбора и обработки данных, обеспечить построение ANN и интегрировать ее в систему управления. Решение этих задач предлагается многими коммерческими организациями, включая бывшее подразделение Сбера – ООО «СберБизнесСофт». Этот вариант подразумевает немалые финансовые затраты при индивидуальном подходе к организации прогнозирования, что доступно лишь крупным компаниям.

Второй возможен при наличии собственного персонала, способного самостоятельно аккумулировать и анализировать данные, осуществлять построение моделей машинного обучения. Здесь возможна экономия затрат, но предполагается наличие необходимых навыков сбора и обработки информации у сотрудников организации.

Мы будем рассматривать случай внедрения ANN в экономический отдел сельскохозяйственной организации. Предполагается, что отдел экономики уже обладает стандартным набором в виде любой клиент-серверной платформы и базы данных. В таком случае требуется интеграция построенной сети с данной системой для информативного отображения графиков и диаграмм.

Практическое решение задач прогнозирования экономических систем возможно с использованием сервисов облачных вычислений, создаваемых в последнее время многими цифровыми операторами. Организовать работу с нейронными сетями глубокого обучения можно с помощью Microsoft Distributed Learning Machine Toolkit, Google Prediction

API, Amazon Machine Learning и ряда других. Условием их использования в субъектах агробизнеса является развертывание микросервисной облачной инфраструктуры. Сервисы должны обладать API в виде gRPC с использованием протокола HTTP/2.0 с подключением мультиплексирования для ускоренной передачи данных. Целесообразно создание трех микросервисов: для предобработки данных, для обучения нейронной сети и для подготовки данных к интеграции и создания интерактивных графиков (рис. 4).

Микросервисная архитектура является наиболее приемлемой в данном случае в связи с легкостью масштабирования и доступностью данных на любом этапе обработки информации. Сервис сбора и предобработки данных отвечает за поиск и сбор данных, валидацию, верификацию и классификацию данных. Сервис должен проводить первичный анализ полученных данных, выполнять нормализацию, стандартизацию, компоновку и векторизацию данных для передачи на вход алгоритму.

Сервис обучения модели непосредственно отвечает за обучение модели и сохранение прогнозных результатов в базу данных. На данном этапе предполагается использование вышеописанной ANN. Длительность обучения модели и результаты прогнозирования критически зависят от качества, количества и дифференциации данных на входе модели. Обучение модели должно проводиться регулярно, но не непрерывно, не допуская ее переобучения. Таким образом, второй микросервис должен запускаться согласно графику, формируемому в зависимости от объема поступающей информации на первый микросервис.

Микросервис пользовательского интерфейса оптимально может быть представлен в виде веб-страницы с отображением результатов работы алгоритма. Наиболее эффективным способом представления прогнозируемых значений является графическое отражение полученных результатов поверх фактических данных. В таком случае прогнозируемые значения подкрепляются фактическими данными из первого микросервиса, что сразу показывает уровень корреляции между прогнозируемыми и фактическими показателями. Дополнительно данный микросервис может использоваться как точка интеграции с другими системами организации, а также дополнительных функций, таких как отправка уведомлений руководству, формирование отчета, взаимосвязь с маркетинговыми инструментами и т. д.

Хотелось бы отметить, что созданием модели и ее развертыванием на предприятии разработка не заканчивается. Высоконагруженные системы, особенно подразумевающие использование алгоритмов машинного обучения, малоустойчивы и склонны к проявлению дефектов в процессе эксплуатации. Более того, в процессе построения подобной

системы постепенно будут появляться новые требования к результатам ее использования, что потребует дополнительных ресурсов для доработки системы и алгоритмов. Однако практика больших организаций, связанных с аналитикой рынка сбыта, показывает, что такие системы способны значительно повысить эффективность сбыта продукции за счет своевременной корректировки цен на продукцию. Также данные, полученные в результате сбора и предобработки, можно на коммерческой основе предоставлять другим субъектам агробизнеса.

Обсуждение и выводы (Discussion and Conclusion)

Проведенная систематизация основных видов ANN с учетом их назначения, сравнения основных положительных и отрицательных сторон позволила выбрать наиболее перспективную с точки зрения применимости в прогнозировании сельскохозяйственных организаций архитектуру с использованием совокупности рекуррентных сетей с алгоритмом обратного распространения: GRU + LSTM. Сформулированные в работе базовые положения методики развертывания нейронных сетей и организации процесса прогнозирования в отдельных экономических субъектах, а также условия совершенствования информационной инфраструктуры на уровне сельскохозяйственных организаций могут быть положены в основу совершенствования системы прогнозирования в сельском хозяйстве.

Искусственные нейронные сети не обязательно являются панацеей и не исключают примене-

ния традиционных методов прогнозирования. Но использование ANN создает новые возможности для экономических агентов, стремящихся решать управленческие задачи, такие как стратегическое управление развитием, оптимизация продаж, улучшение логистики, услуг и многих других, с помощью новых средств. Подобные модели могут быть полезны для повышения объективности, оперативности, точности прогнозов, а также повышения скорости и производительности работ в процессе прогнозирования. Лучшее понимание происходящих на агропродовольственных рынках процессов будет способствовать принятию взвешенных управленческих решений при планировании производственной программы, формированию и реализации оптимальной ценовой стратегии, принятию решений по своевременной дифференциации и оперативной корректировке уровня цен, улучшению работы с потребителями.

Отдельные организационные аспекты безусловно требуют дополнительных усилий в данном направлении, что может быть реализовано в дальнейшем, посредством новых исследований этой темы. При этом следует констатировать, что с развитием цифровых технологий именно методы машинного обучения постепенно становятся основой прогнозирования будущего состояния различных экономических систем, в том числе агропродовольственных.

Библиографический список

1. Булыгина О. В., Емельянов А. А., Росс Г. В., Яшин Е. С. Инвестиции, инновации, импортозамещение: имитационное моделирование с элементами искусственного интеллекта в управлении проектными рисками // Прикладная информатика. 2020. Т. 15, № 1 (85). С. 63–102. DOI: 10.24411/1993-8314-2020-10006.
2. Тормозов В. С., Кулпейс Е. А., Смагулова К. К. [и др.] Метод автоматизированного краткосрочного прогнозирования временного ряда в онлайн-режиме // Промышленные АСУ и контроллеры. 2021. № 7. С. 32–40. DOI: 10.25791/asu.7.2021.1296.
3. Самыгин Д. Ю., Барышников Н. Г., Мизюркина Л. А. Модели сценарного прогнозирования развития сельского хозяйства региона // Экономика региона. 2019. Т. 15, № 3. С. 865–879. DOI: 10.17059/2019-3-18.
4. Abbasimehr H., Shabani M., Yousefi M. An optimized model using LSTM network for demand forecasting // Computers and Industrial Engineering. 2020. Vol. 143. Article number 106435. DOI: 10.1016/j.cie.2020.106435.
5. Blühdorn I., Deflorian M. The Collaborative Management of Sustained Unsustainability: on the performance of participatory forms of environmental governance // Sustainability. 2019. Vol. 11, No. 4. Article number 1189. DOI: 10.3390/su11041189.
6. Dubovitski A. A., Yakovleva E. A., Smyslova O. Y., Kochyan G. A., Zelenkina E. V. Assessment of export prospects of Russian agricultural producers // Environmental Footprints and Eco-Design of Products and Processes. 2022. Pp. 167–180. DOI: 10.1007/978-981-16-8731-0_17.
7. Dubovitski A., Klimentova E., Rogov M. Applicability of machine learning models using a neural network for predicting the parameters of the development of food markets // Journal of Process Management and New Technologies. 2022. Vol. 10, No. 3–4. Pp. 93–105. DOI: 10.5937/jpmnt10-41317.
8. Food Access Research Atlas. Economic Research Service, Department of Agriculture USA [Электронный ресурс]. URL: <https://catalog.data.gov/dataset/food-access-research-atlas> (дата обращения: 10.11.2020).
9. Guo Y., Tang D., Tang W., Yang S., Tang Q., Feng Y., Zhang F. Agricultural Price Prediction Based on Combined Forecasting Model under Spatial-Temporal Influencing Factors // Sustainability. 2022. Vol. 14, No. 17. Article number 10483. DOI: 10.3390/su141710483.

10. Haynes P., Alemna D. A Systematic literature review of the impact of complexity theory on applied economics // *Economies*. 2022. Vol. 10, No. 8. Article number 192. DOI: 10.3390/economies10080192.
11. Karpunina E. K., Kosorukova I. V., Dubovitski A. A., Galieva G. F., Chernenko E. M. State policy of transition to Society 5.0: Identification and assessment of digitalisation risks // *International Journal of Public Law and Policy*. 2021. Vol. 1, No. 7. Pp. 334–350. DOI: 10.1504/IJPLAP.2021.118895.
12. Kriegeskorte N., Golan T. Neural Network Models and Deep Learning // *Current Biology*. 2019. Vol. 29, No. 7. R231–R236. DOI: 10.1016/j.cub.2019.02.034.
13. Kumar P., Suresh S. DeepTransHAR: a novel clustering-based transfer learning approach for recognizing the cross-domain human activities using GRUs (Gated Recurrent Units) Networks // *Internet of Things*. 2023. Vol. 21. Article number 100681. DOI: 10.1016/j.iot.2023.100681.
14. Molnar C. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* (2nd ed.) [Электронный ресурс]. 2022. URL: <https://christophm.github.io/interpretable-ml-book> (дата обращения: 15.01.2023).
15. Paskins M. History of science and its utopian reconstructions // In: *Studies in History and Philosophy of Science*. Part A. 2020. Vol. 81. Pp. 82–95. DOI: 10.1016/j.shpsa.2019.08.001.
16. Sabzipour B., Arsenault R., Troin M., Martel J., Brissette F., Brunet F., Mai J. Comparing a long short-term memory (LSTM) neural network with a physically-based hydrological model for streamflow forecasting over a Canadian catchment // *Journal of Hydrology*. 2023. Vol. 627, Part A. Article number 130380. DOI: 10.1016/j.jhydrol.2023.130380.
17. Zhou H., Zhu H., Wang X. Change point detection via feedforward neural networks with theoretical guarantees // *Computational Statistics & Data Analysis*. 2024. Vol. 193. Article number 107913. DOI: 10.1016/j.csda.2023.107913.

Об авторах:

Александр Алексеевич Дубовицкий, доктор экономических наук, доцент кафедры экономики и коммерции, Мичуринский государственный аграрный университет, Мичуринск, Россия; ORCID 0000-0003-4542-1119, AuthorID 315247. E-mail: daa1-408@yandex.ru

Эльвира Анатольевна Климентова, кандидат экономических наук, доцент кафедры экономики и коммерции, Мичуринский государственный аграрный университет, Мичуринск, Россия; ORCID 0000-0001-7628-7181, AuthorID 343886. E-mail: klim1-408@yandex.ru

References

1. Bulygina O. V., Emelyanov A. A., Ross G. V., Yashin E. S. Investments, innovations, import substitution: simulation modeling with elements of artificial intelligence in project risk management. *Journal of Applied Informatics*, 2020; 15 (1): 63–102. DOI: 10.24411/1993-8314-2020-10006. (In Russ.)
2. Tormozov V. S., Kulpeys E. A., Smagulova K. K., et al. Method of automated short-term forecasting of a time series in online mode. *Industrial Automatic Control Systems and Controllers*. 2021; 7: 32–40. DOI: 10.25791/asu.7.2021.1296. (In Russ.)
3. Samygin D. Yu., Baryshnikov N. G., Mizyurkina L. A. Models of Scenario Forecasting of the Region's Agriculture. *Economy of Regions*. 2019; 15 (3): 865–879. DOI: 10.17059/2019-3-18. (In Russ.)
4. Abbasimehr H., Shabani M., Yousefi M. An optimized model using LSTM network for demand forecasting. *Computers and Industrial Engineering*. 2020; 143: 106435. DOI: 10.1016/j.cie.2020.106435.
5. Blühdorn I., Deflorian M. The Collaborative Management of Sustained Unsustainability: on the performance of participatory forms of environmental governance. *Sustainability*. 2019; 11 (4): 1189. DOI: 10.3390/su11041189.
6. Dubovitski A. A., Yakovleva E. A., Smyslova O. Y., Kochyan G. A., Zelenkina E. V. Assessment of export prospects of Russian agricultural producers. *Environmental Footprints and Eco-Design of Products and Processes*. 2022: 167–180. DOI: 10.1007/978-981-16-8731-0_17.
7. Dubovitski A., Klimentova E., Rogov M. Applicability of machine learning models using a neural network for predicting the parameters of the development of food markets. *Journal of Process Management and New Technologies*. 2022; 10 (3–4): 93–105. DOI: 10.5937/jpmnt10-41317.
8. *Food Access Research Atlas*. Economic Research Service, Department of Agriculture USA [Internet] [cited 2020 Nov 10]. Available from: <https://catalog.data.gov/dataset/food-access-research-atlas>.
9. Guo Y., Tang D., Tang W., Yang S., Tang Q., Feng Y., Zhang F. Agricultural Price Prediction Based on Combined Forecasting Model under Spatial-Temporal Influencing Factors. *Sustainability*. 2022. Vol. 14, No. 17. Article number 10483. DOI: 10.3390/su141710483.
10. Haynes P., Alemna D. A Systematic literature review of the impact of complexity theory on applied economics. *Economies*. 2022; 10 (8): 192. DOI: 10.3390/economies10080192.

11. Karpunina E. K., Kosorukova I. V., Dubovitski A. A., Galieva G. F., Chernenko E. M. State policy of transition to Society 5.0: Identification and assessment of digitalisation risks. *International Journal of Public Law and Policy*. 2021; 1 (7): 334–350. DOI: 10.1504/IJPLAP.2021.118895.
12. Kriegeskorte N., Golan T. Neural Network Models and Deep Learning. *Current Biology*. 2019; 29 (7): R231–R236. DOI: 10.1016/j.cub.2019.02.034.
13. Kumar P., Suresh S. DeepTransHAR: a novel clustering-based transfer learning approach for recognizing the cross-domain human activities using GRUs (Gated Recurrent Units) Networks. *Internet of Things*. 2023; 21: 100681. DOI: 10.1016/j.iot.2023.100681.
14. Molnar C. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* (2nd ed.) [Internet]. 2022 [cited 2023 Jan 15]. Available from: <https://christophm.github.io/interpretable-ml-book>.
15. Paskins M. History of science and its utopian reconstructions. *Studies in History and Philosophy of Science. Part A*. 2020; 81: 82–95. DOI: 10.1016/j.shpsa.2019.08.001.
16. Sabzipour B., Arsenault R., Troin M., Martel J., Brissette F., Brunet F., Mai J. Comparing a long short-term memory (LSTM) neural network with a physically-based hydrological model for streamflow forecasting over a Canadian catchment. *Journal of Hydrology*. 2023; 627 (A): 130380. DOI: 10.1016/j.jhydrol.2023.130380.
17. Zhou H., Zhu H., Wang X. Change point detection via feedforward neural networks with theoretical guarantees. *Computational Statistics & Data Analysis*. 2024; 193: 107913. DOI: 10.1016/j.csda.2023.107913.

Authors' information:

Aleksandr A. Dubovitskiy, doctor of economic sciences, associate professor of the department of economics and commerce, Michurinsk State Agrarian University, Michurinsk, Russia; ORCID 0000-0003-4542-1119, AuthorID 315247. *E-mail*: daal-408@yandex.ru

Elvira A. Klimentova, candidate of economic sciences, associate professor of the department of economics and commerce, Michurinsk State Agrarian University, Michurinsk, Russia; ORCID 0000-0001-7628-7181, AuthorID 343886. *E-mail*: klim1-408@yandex.ru