

## ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ ВРЕМЕННЫХ РЯДОВ

*Китова О.В., доктор экономических наук, доцент,  
Дьяконова Л.П., кандидат физико-математических наук, доцент,  
Китов В.А., кандидат технических наук, старший научный сотрудник,  
Савинова В.М., старший преподаватель,  
Российский экономический университет им. Г.В. Плеханова*

*Работа выполнена при поддержке РФФИ, грант №20-57-00024*

**Аннотация:** целью исследования является обоснование выбора архитектур искусственных нейронных сетей для включения в нейросетевой модуль разрабатываемой авторами гибридной системы краткосрочного прогнозирования «СГМ Горизонт». Система гибридных моделей и программный комплекс «СГМ Горизонт» предназначены для прогнозирования макроэкономических показателей на уровне страны и регионов. Гибридный подход обеспечивает достижение необходимого качества прогнозов для всей системы показателей. Ключевую роль здесь играют модели нейронных сетей. В статье приводится обзор работ по применению нейронных сетей в прогнозировании, особое внимание уделено исследованиям в области прогнозирования экономических временных рядов. Методологической базой исследования является гибридный подход, включающий наряду с эконометрическими моделями модели машинного обучения, такие как нейронные сети и деревья решений. Для прогнозирования экономических показателей на основе нейронных сетей используются две базовые архитектуры: сети прямого распространения и рекуррентные сети. В сетях прямого распространения для прогнозирования временных рядов применяется многослойный персептрон, в рекуррентных – архитектура сети с долговременной и кратковременной памятью (LSTM). На основании проведенного анализа инструментов для решения задач моделирования на основе нейронных сетей для их реализации в «СГМ Горизонт» использовались функции библиотеки языков C++ и C# FANN (Fast Artificial Neural Network). В рамках «СГМ Горизонт» разработан модуль Искусственных нейронных сетей, позволяющий проводить прогнозирование временных рядов на основе архитектур многослойного персептрона и рекуррентных сетей с долговременной и кратковременной памятью (LSTM). В системе «СГМ Горизонт» проведено прогнозирование показателей макроэкономики, государственных бюджетов, социальной сферы и внешнеэкономической деятельности Российской Федерации. На первом этапе в системе проводится прогнозирование всех показателей на основе регрессионной модели. В результате из общего числа 175 показателей высокие значения точности и качества были получены для 125 показателей. На втором этапе для остальных 50 показателей средствами модуля нейронных сетей были построены нейросетевые прогнозные модели. Для 45 показателей были получены результаты удовлетворительной точности. Разработанный авторами гибридный подход к моделированию и прогнозированию социально-экономических показателей РФ позволяет добиться высокой точности прогноза для всей исследуемой совокупности показателей. Проведенное в системе «СГМ Горизонт» прогнозирование показателей макроэкономики, государственных бюджетов, социальной сферы и внешнеэкономической деятельности Российской Федерации демонстрирует эффективность такого подхода. Расчеты на основе архитектуры многослойного персептрона по прогнозированию 45 из 50 показателей дали более точные прогнозы по сравнению с базовой регрессионной моделью.

**Ключевые слова:** искусственные нейронные сети, социально-экономические показатели РФ, прогнозирование, временные ряды, гибридная информационно-аналитическая система

Искусственные нейронные сети (ИНС) превратились в мощный метод машинного моделирования. Они продемонстрировали способность решать различные прикладные задачи в широком спектре областей. В настоящее время развиваются подходы к применению нейронных сетей к задачам экономического анализа и прогнозирования.

Нейросети широко используются для решения задач прогнозирования, в том числе в экономике и бизнесе.

Исследования в области финансов и экономического моделирования имеют долгую историю. Анализ временных рядов – один из наиболее широко используемых базовых подходов к моделированию экономики и финансов.

Традиционно наиболее широко используемыми в прогнозировании экономических рядов являются линейные методы. Однако зачастую в реальных задачах между исследуемыми показателями существуют скрытые нелинейные зависимости, которые не всегда можно учесть с помощью линейного моделирования.

Нейронные сети как нелинейные методы все шире применяются в экономике и финансах, поскольку нейронные сети имеют более общие функциональные формы, чем те, с которыми можно эффективно справиться с помощью хорошо разработанных статистических методов.

В настоящее время существует множество инструментов для построения и обучения нейросетевых моделей любой сложности, что способствует быстрому росту разработок в области прогнозирования на основе ИНС. Появление бесплатных библиотек для машинного обучения позволяет исследователям использовать готовые модели нейронных сетей и методов их обучения для решения задач анализа.

В статье дается обзор работ по нейросетевым методам, особое внимание уделяется архитектурам и моделям прогнозирования на основе нейросетей. Описываются две основных архитектуры: многослойный персептрон и рекуррентные сети.

В то же время прогнозирование экономических показателей не может быть качественно решено на основе анализа отдельных временных рядов и отдельных моделей. Авторы развивают гибридный подход, основанный на построении прогнозной системы, реализующей регрессионные, нейросетевые и другие модели, причем выбор нужной модели осуществляется на основе модуля оценки качества и точности прогнозов.

В статье рассматривается прогнозирование экономических показателей РФ в системе «СГМ Горизонт» с применением нейросетевой модели.

В настоящее время насчитывается более 20 архитектур ИНС [1]. В целом они подразделяются на сети прямого распространения и рекуррентные сети и двунаправленные сети [2].

В области экономики искусственные нейронные сети применяются для макроэкономического прогнозирования [3, 4], ценообразования и прогнозирования финансовых активов [5, 6]. В последнее время ИНС стали использовать для оценки причинно-следственных связей [7], дизайна аукциона [8], ценообразования активов и управления рисками [9, 10].

Важным направлением, в котором успешно применяются искусственные нейронные сети, является прогнозирование.

Один из первых обзоров применения нейросетей в прогнозировании явилась работа [11], в которой рассматривается методология прогнозирования с помощью ИНС-моделей и приводится сравнение результатов прогнозирования на основе многослойного персептрона и статистических методов для временных рядов из разных областей. Обзор показал, что ИНС превосходит модель Бокса-Дженкинса для временных рядов ИНС с короткой памятью или с большей нерегулярностью. В работе [12] рассматриваются исследования по прогнозировании финансовых и экономических показателей на основе моделей нейронных сетей, а также традиционных статистических подходов (статистические методы анализа временных рядов и множественная регрессия. Проводится сравнение возможностей ряда архитектур и моделей нейронных сетей, а также традиционных статистических подходов. Авторы работ [11, 12] отмечают, что не существует универсального подхода и предлагают объединить несколько разных моделей для повышения эффективности прогнозирования.

В работе [13] рассматривается подход к эффективному моделированию с помощью многослойного персептрона временных рядов, имеющих сезонную компоненту и тренд. На модельных и реальных экономических данных авторы показывают, что после выделения сезонной компоненты и тренда результат прогнозирования на нейронных сетях значительно превосходит по качеству и точности прогнозов сезонные модели ARIMA.

В статье [14] модель многослойного персептрона применяется для прогнозирования темпов роста ВВП 15 промышленно развитых стран в период 1996-2016 гг. Результаты исследования демонстрируют, что модель ИНС способна давать гораздо более точные прогнозы темпов роста ВВП, чем соответствующая линейная модель.

В работе [15] проводится сравнение двух типов искусственных нейронных сетей прямого распространения, MLP NN и RBF NN и двух алгоритмов обучения – Back-propagation и Levenberg-Marquardt для построения краткосрочных и среднесрочных прогнозов экономического индекса – показателя Расходы на потребление домашних хозяйств. Авторы делают вывод, что архитектура MLP NN лучше RBF NN и алгоритм Back-propagation превосходит Levenberg-Marquardt.

В статье [16] проводится сравнение со статистическими моделями целого ряда архитектур нейронных сетей (многослойные

персептроны (MLP), рекуррентные нейронные сети (RNN), нейронные сети общей регрессии (GRNN), модульные, обучающее векторное квантование (LVQ), радиальный базис. функциональные сети (RBFN), нечеткая сеть ARTMAP, вероятностная нейронная сеть (PNN)) для экономических рядов. Авторы предлагают процедуру комбинирования различных моделей и интегрировать нейромодели с другими технологиями.

Значительное число исследований посвящено применению для прогнозирования экономических рядов рекуррентных нейронных сетей, в большинстве работ используются различные модификации архитектуры сети с долговременной и кратковременной памятью LSTM.

В работе [17] представлен онлайн-метод обучения рекуррентной сети LSTM для прогнозирования временных рядов при наличии как выбросов, так и точек изменения. Использован метод адаптивного градиентного обучения для рекуррентных нейронных сетей (RNN) для прогнозирования потоковых временных рядов при наличии аномалий и точек изменения. Проведен обширный экспериментальный анализ как на синтетических, так и на реальных наборах данных, подтверждающий эффективность предлагаемого метода.

Авторы работы [18] представили модель прогнозирования, которая может использоваться с различными типами моделей RNN в подгруппах схожих временных рядов, которые идентифицируются методами кластеризации временных рядов. Предложена методология популярного варианта RNN, сетей LSTM. Авторский метод превосходит базовую модель LSTM и все другие методы на наборе данных для прогнозирования конкуренции CIF2016.

В работе [19] предлагается новая сквозная архитектура рекуррентной нейронной сети, которая показала свое превосходство в прогнозировании событий на данных компании Uber. В статье изучается использование рекуррентных нейронных сетей (RNN) для моделирования и прогнозирования временных рядов экономических показателей, содержащих пропущенные значения.

Работа демонстрирует Алмосова [20] ценность методов нелинейного машинного обучения для прогнозирования макроэкономических временных рядов. Авторы показали, что рекуррентная нейронная сеть с долговременной краткосрочной памятью (LSTM) превосходит линейную авторегрессионную модель (AR), модель случайного блуждания (RW), сезонную авторегрессионную модель (SARIMA), модель

марковского переключения (MS-AR) и простую модель полносвязной нейронной сети (NN) для прогнозирования ежемесячного CPI в США.

В работе [21] представлена схема прогнозирования временных рядов на основе популярных моделей рекуррентных нейронных сетей LSTM и GRU. Рекуррентные нейронные сети намного более гибкие и лучше подходят для прогнозирования временных рядов, чем обычно применяемые линейные модели. Сети LSTM и GRU показали примерно одинаковую эффективность прогнозирования.

В работах [22-23] рассматривается моделирование многомерных временных рядов макроэкономических показателей из США на основе моделей MRNN, VAR и RNN. В этих работах исследуется применимость ИНС семейства RNN и, в частности, Long-Short-Term Memory к многомерным временным рядам. Традиционно в экономике моделирование многомерных временных рядов реализуется с помощью векторной авторегрессии, которую авторы используют в качестве базовой модели. С другой стороны, многомерная рекуррентная нейронная сеть LSTM выполняет ту же роль, дополнительно допуская сильно нелинейные отношения, а также зависящую от состояния динамику данных. В статье [23] рассматривается ряд моделей MRNN LSTM с долгосрочной краткосрочной памятью от малых до крупных и проводится их сравнение с VAR в приложении к данным США по росту ВВП, инфляции, ценам на сырьевые товары, ставке ФРС и банковских резервах. Преимуществом моделей LSTM для макроэкономического прогнозирования является нелинейный характер ИНС, а также способность MRNN LSTM учитывать условную динамику переменных состояния моделируемой системы.

Статья [24] рассматривает класс RNN, называемый нейронными сетями с исправлением ошибок (ECNN). Модель проверена на прогнозах фондового рынка. Результаты превзошли простые RNN и LSTM и другие гибридные модели, которые включают в себя этап предварительной обработки шумоподавления.

В целом можно сделать вывод, что при наличии нелинейных зависимостей в экономических временных рядах хорошо работают архитектуры многослойного персептрона и рекуррентных LSTM-сетей.

Для решения задач моделирования на основе ИНС в настоящее время существует несколько уровней программных средств. Это: платформы для анализа данных и машинного обучения (Data Science and Machine Learning, DSML); универсальные библиотеки и сервисы машинного

обучения; библиотеки машинного обучения языков программирования.

Рынок DSML-платформ быстро развивается. Аналитики компании Gartner отмечают, что все современные платформы DSML включают базовый продукт машинного обучения и портфель интегрированных продуктов, компонентов, библиотек и фреймворков (проприетарных, партнерских и открытых).

Платформы DSML предлагают сочетание базовой и расширенной функциональности, необходимое для создания решений DSML, в первую очередь, прогнозных и предписывающих моделей. Платформы поддерживают внедрение этих решений в бизнес-процессы, окружающую инфраструктуру, продукты и приложения.

К лидерам DSML-платформ 2020 г. компания Gartner относит следующие продукты (указан базовый продукт): Alteryx Designer, SAS Visual Data Mining and Machine Learning, Databricks, TIBCO Data Science, Data Science Studio (компания Dataiku), MATLAB. К провидцам в настоящее время относятся Microsoft Azure Machine Learning, DataRobot, KNIME Analytics Platform, RapidMiner Studio, Google Cloud AI Platform, H2O Driverless AI, Domino.

Большие перспективы имеет отечественная аналитическая платформа Loginom. Платформа обеспечивает все процессы конвейера по анализу данных вплоть до создания готовых аналитических решений и сервисов. В платформу включены алгоритмы машинного обучения: нейронные сети, кластеризация, классификация, ассоциативные правила и прочие.

Универсальные библиотеки и сервисы машинного обучения обеспечивают специалистов по анализу данных необходимым функционалом для создания проектов на таких языках как питон, C++, C# и др. Все далее описанные библиотеки имеют открытый исходный код, реализуют модели нейронных сетей различной архитектуры, наряду с другими методами машинного обучения.

Библиотека от компании Google TensorFlow (<https://www.tensorflow.org/>) реализует вычисления с многомерными матрицами (тензорами) с использованием графов потоков данных, между которыми передаются тензоры. TensorFlow позволяет писать программы на языках Python, C++.

Theano (<http://deeplearning.net/software/theano/>) – библиотека для языка Python, так же как и TensorFlow, обеспечивает работу с многомерными матрицами. Для работы с нейросетями, как и в TensorFlow, необходимо поверх эффективных вычислений тензоров самостоятельно организовать нейросеть.

Keras (<http://keras.io/>) – библиотека глубокого обучения для TensorFlow и Theano, позволяет просто и быстро описать нейронных сети, указать конфигурацию нейронной сети, задать функцию активации, метод оптимизации и другие параметры для обучения сети.

Caffe ([caffe.berkeleyvision.org](http://caffe.berkeleyvision.org)) – библиотека для глубокого обучения, поддерживает интерфейс на языке Python, совместима с MATLAB.

Microsoft Cognitive Toolkit (CNTK) (<http://www.cntk.ai/>) поддерживает языки Python, C++, C#, BrainScript. В библиотеке сделан упор на глубокое обучение, в большой степени на нейронные сети с рекуррентной архитектурой.

Torch (<http://torch.ch/>) – MATLAB-подобная библиотека для языка программирования Lua с открытым исходным кодом, предоставляет большое количество алгоритмов для глубокого обучения и научных расчетов.

PyTorch (<https://pytorch.org/>) – библиотека машинного обучения для языка Python с открытым исходным кодом, созданная на базе Torch.

MXNet – это современная библиотека глубокого обучения, которая может поддерживать несколько машин. В ней поддерживается гибкая модель программирования на нескольких языках программирования (C ++, Python, Julia, MATLAB, JavaScript, Go, R, Scala, Perl и Wolfram Language).

Библиотека FANN (Fast Artificial Neural Network) (<http://leenissen.dk/fann/wp/>) позволяет реализовать искусственные нейронные сети на языке C. К библиотеке возможен доступ из более чем 20 языков программирования, включая C++, C#, Java, Python, Lua, R.

Важной задачей стратегического планирования и управления является построение системы краткосрочного прогнозирования социально-экономических показателей. Существенную роль здесь играл и остается актуальным эконометрический подход на основе систем регрессионных уравнений, впервые предложенный Нобелевским лауреатом Р.Л.Клейном [25]. В работах Т.Нейлора [26] и А.П. Ермилова [27] приведены аналитические обзоры, математическое описание моделей и результаты экспериментов. В монография Ю.А. Чижова [28] описаны эконометрические страновые модели, даются рекомендации разработчиков моделей по проектированию и разработке прогнозных систем. Дж.Форрестер [29] рассмотрел применение системной динамики для изучения сложных социально-экономических систем.

В работе И.Б. Колмакова [30] приводится обзор эконометрических моделей западной экономики. Эконометрические страновые модели Российской

Федерации в условиях рыночной экономики описаны в работе В.С. Лисина и др. [31].

Однако применение регрессионных линейных уравнений для прогнозирования экономических показателей имеет свои ограничения, что связано со следующими факторами:

1) Существенно нелинейные зависимости между показателями;

2) Появление новых показателей с короткими (неполными) рядами отчетных данных;

3) Несопоставимость отчетных данных показателя вследствие изменения методики его расчета;

4) Неполнота наборов отчетных показателей Росстата РФ в Системе Национальных Счетов (СНС) (например, отсутствие индекс-дефляторов для компонентов структур ВВП);

5) Использование показателей со скрытыми (ненаблюдаемыми) наборами факторов влияния;

6) Появление признаков потери статистической значимости показателя;

7) Зависимость значений показателя от постановлений законодательной или исполнительной власти и т.п. («директивные» показатели).

Во всех этих случаях возможности эконометрических моделей для ряда показателей могут быть исчерпанными. В настоящее время возникшие проблемы решаются путем создания гибридных моделей, сочетающих регрессионные и интеллектуальные методы, включая нейронные сети, регрессионные деревья решений и др., а также нейро-нечеткими моделями ANFIS (adaptive neuro-fuzzy inference system) [32-35].

В РЭУ им. Г.В. Плеханова авторами статьи развивается специализированная информационно-

аналитическая система «СГМ Горизонт», позволяющая осуществлять сценарное среднее и краткосрочное прогнозирование более 600 социально-экономических показателей РФ на основе ансамбля гибридных моделей, сочетающих модели и методы множественной линейной регрессии с моделями нейронных сетей (многослойных персептронов) и регрессионных деревьев решений.

Принятый в системе «СГМ Горизонт» сценарный подход, структура моделей экономических показателей, архитектура системы описаны в серии работ [36-39].

Следует отметить, что все остальные системы прогнозирования социально-экономических показателей РФ, направлены на решение отдельных частных задач, кроме того, являются закрытыми проприетарными системами.

Эконометрическая модель системы «СГМ Горизонт» включает систему уравнений множественной линейной регрессии для всех исследуемых показателей. При построении уравнений учитываются влияющие на каждый показатель факторы, а также проводится расчет коэффициентов корреляции показателей. Траектория развития определяется прогнозами сценарных показателей, основанными на экспертных оценках. В качестве сценарных показателей задаются мировые цены на нефть, темп роста денежной массы, изменение золотовалютных резервов, ключевая ставка ЦБ. Система эконометрических моделей представлена на рис. 1.

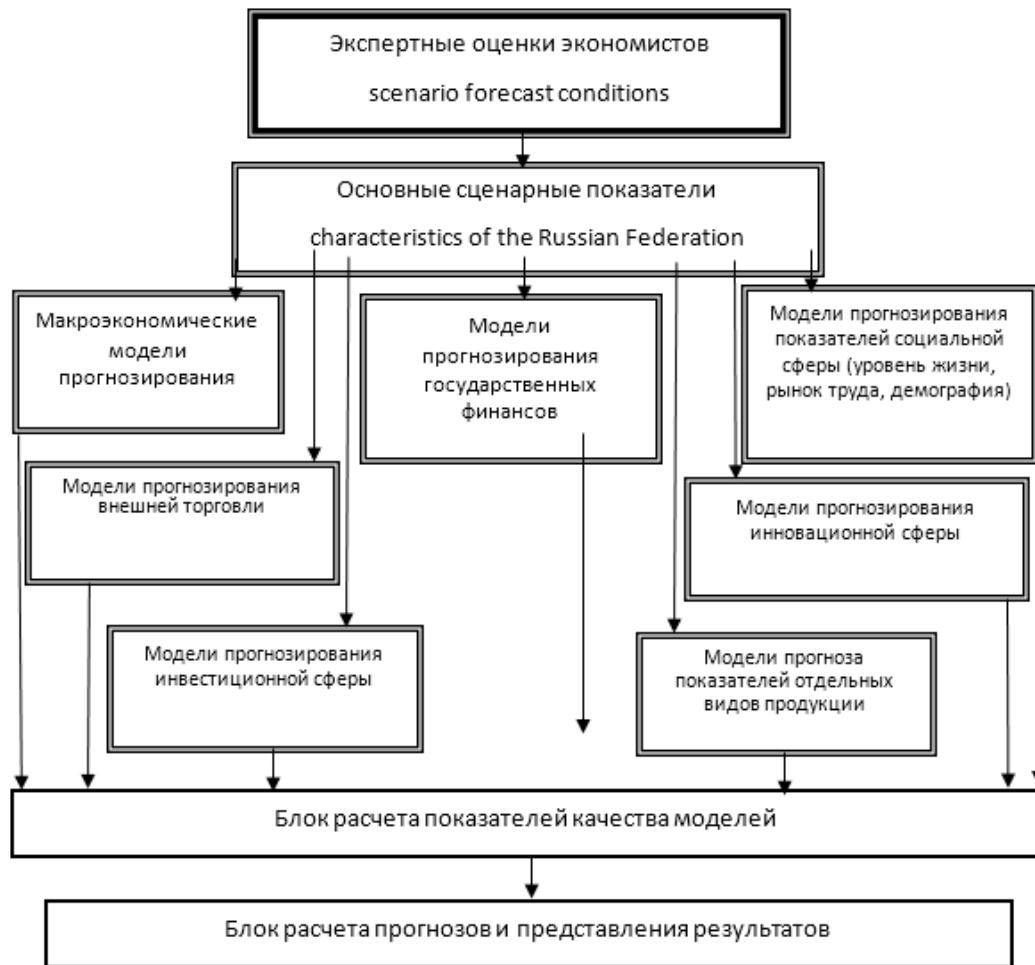


Рис. 1. Структура эконометрических моделей системы «СГМ Горизонт»

В Блоке расчета показателей качества моделей для заданного сценария и для каждого показателя производятся расчеты критериев качества прогнозной модели: коэффициент детерминации ( $R^2$ ), Дарбина-Уотсона (DW), критерия Фишера (F). Для расчета точности прогнозов на ретро-

прогнозе производится расчет средней относительной ошибки (MAPE). Значения критериев точности и качества, при которых модель считается пригодной для прогнозирования, задаются экспертным путем (см. табл. 1).

Таблица 1

**Критерии качества и точности**

**Настройки оценок качества**

коэффициент детерминации ( $R^2$ ),	> 0,4
значения статистики Фишера (F-stat).	> 5,0
критерий Дарбина-Уотсона (DW)	0,8 < DW < 3,2

**Настройки оценок точности ( $\Delta$ )**

High	Middle	Low
<0,06	0,06 < $\Delta$ < 0,16	>0,16

Важным этапом (1974, 1986) явилась разработка эффективного алгоритма обратного распространения ошибки для обучения многослойных перцептронов [40-43], что в 1980-е годы, наряду с появившимися в то время доступными и высокопроизводительными персональными компьютерами дало толчок к

развитию и применению обучаемых нейронных сетей.

Система «СГМ Горизонт» разработана средствами языка Python и включает в себя как эконометрические, так и интеллектуальные модели прогнозирования. Как показывают наши эксперименты с расчетом показателей РФ для социальной сферы [37] и сферы научных

исследований и инноваций [53], применение нейросетевых моделей для прогнозирования ряда показателей, для которых регрессионная модель не дает удовлетворительных результатов,

позволило реализовать качественные и точные прогнозы для всей совокупности показателей.

Компоненты системы представлены на рис. 2.

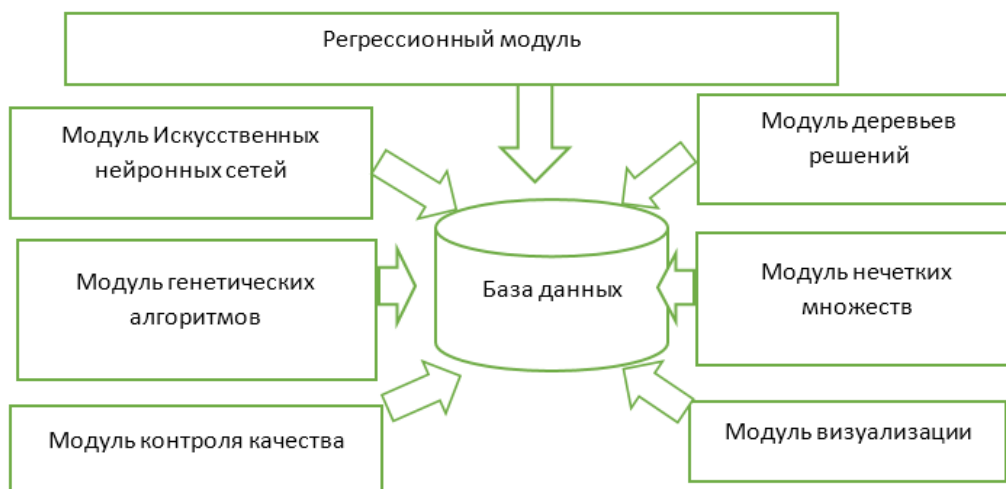


Рис. 2. Компоненты система «СГМ Горизонт»

Разработка системы ведется средствами языка C# на платформе DotNet (.core), благодаря чему система является кросс-платформенной. В качестве системы управления базами данных для разрабатываемого программного обеспечения выступают Postgress и Microsoft SQL Server. Одновременно работающих пользователей в системе предполагается не менее 1000.

Пользовательская часть системы разрабатывается, как SPA (Single page application), реализованное с использованием технологии VUE.js (JavaScript-фреймворк для создания пользовательских интерфейсов) и применением библиотек bootstrap. Верстка и доработка исходных шаблонов осуществляется с использованием технологий HTML5 и CSS3.

Модуль "Нейронные сети" реализован средствами языка C# и библиотеки FANN. Библиотека FANN создана на языке c++ и была адаптирована для языка c#. Библиотека позволяет осуществлять построение многослойных персептронов и проводить обучение сети с использованием метода backprop. В библиотеке FANN присутствует метод создания нейронной сети, который принимает на вход количество слоев и количество нейронов на каждом слое. В рамках указанного метода выбирается функция активации (relu, сигмоида, гиперболический тангенс и др.). В библиотеке FANN существует метод обучения сети, принимающий в качестве параметра скорость обучения, количество эпох и

допустимую ошибку на обучающей и тестовой выборках. Начальные веса задаются матрицей весов. Результатами работы метода являются ошибки обучения, результаты расчёта на каждом этапе нейронной сети и веса.

В рамках построения моделей прогнозирования показателей макроэкономики, государственных бюджетов, социальной сферы и внешнеэкономической деятельности Российской Федерации описанная выше регрессионная модель для общего числа 175 показателей дала высокие значения точности и качества для 125 показателей и средние или низкие показатели качества и точности для остальных 50 показателей.

Для этих 50 показателей были построены нейросетевые прогнозные модели на базе модуля нейронных сетей. Для 45 из 50 показателей были получены более точные результаты по сравнению с регрессионной моделью.

В качестве архитектуры был выбран персептрон с одним скрытым слоем и 10 нейронами на скрытом слое. Обучение проводилось с использованием метода обратного распространения ошибки со скоростью обучения равной 0,3, моментом обучения 0,6, количество эпох – 70.

В качестве примера успешности нейросетевой модели приведем ретропрогнозы по регрессионной и нейросетевой моделям для показателя «Покупка товаров и услуг в процентах от дохода» (см. рис. 3 и рис. 4).

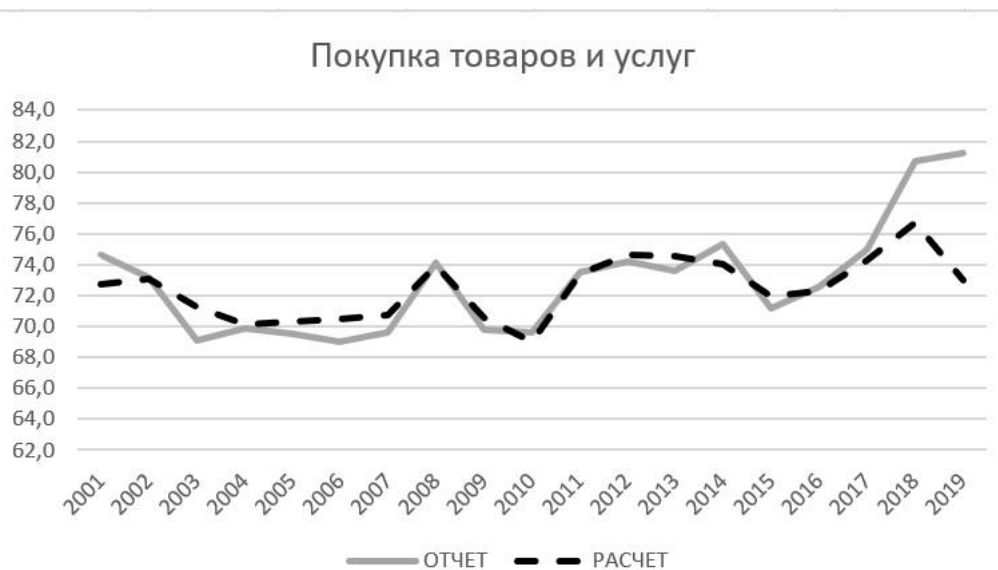


Рис. 3. Результат расчета уравнения линейной регрессии для показателя Покупка товаров и услуг в процентах от дохода




Рис. 4. Результат расчета модели нейронной сети для показателя Покупка товаров и услуг в процентах от дохода

Как видно из приведенных графиков, с использованием нейронной сети удалось построить модель прогнозирования более

высокого качества. Точность полученных прогнозов также выше, чем у множественной линейной регрессии (см. табл. 2).

Таблица 2

**Значение критериев верификации для показателя Покупка товаров и услуг в процентах от дохода**

Регрессионная модель		Искусственная нейронная сеть	
R2	Ошибка	R2	Ошибка
0,7	13%	0,99	0,3 %

В системе «СГМ Горизонт» реализован гибридный подход к построению моделей и прогнозов, при котором на первом этапе строится регрессионная модель по всем исследуемым показателям, затем проверяется множественная регрессионная модель на основе экспертных оценок значений качества и точности, а на третьем

этапе осуществляется использование интеллектуальных моделей для показателей с неудовлетворительными значениями на основе машинного обучения.

Представленное исследование позволило получить следующие результаты:

На основании обзора исследований в области



прогнозирования экономических рядов на основе моделей нейронных сетей и машинных экспериментов авторов настоящей работы осуществлен выбор архитектур нейронных сетей для использования в нейросетевом модуле системы «СГМ Горизонт»: многослойный перцептрон и рекуррентная сеть LSTM.

В рамках системы «СГМ Горизонт» разработан модуль искусственных нейронных сетей, в котором реализованы архитектуры многослойного перцептрона и рекуррентной LSTM-сети и обеспечен процесс обучения и прогнозирования на базе этих архитектур.

Средствами системы «СГМ Горизонт» выполнено прогнозирование совокупности из 150 показателей макроэкономики, государственных бюджетов, социальной сферы и внешнеэкономической деятельности Российской Федерации с использованием гибридных моделей.

Для 125 из 175 показателей регрессионная модель показала высокие и удовлетворительные значения качества и точности; для 45 из оставшихся 50 повышение качества и точности прогноза было достигнуто за счет использования модели искусственных нейронных сетей на основе архитектуры многослойного перцептрона.

### Литература

1. Fjodor van Veen. *The neural network zoo*. 2016. <https://www.asimovinstitute.org/neural-network-zoo/>
2. Саймон Хайкин. *Нейронные сети: полный курс = Neural Networks: A Comprehensive Foundation*. 2-е изд. М.: «Вильямс», 2006.
3. Swanson, Norman R., and Halber White. "A Model Selection Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks" // *Review of Economics and Statistics*. 1997. № 79 (4). P. 540 – 550.
4. Chen, Xiaohong, Jeffrey Racine, and Norman R. Swanson. "Semiparametric ARX Neural Network Models with an Application to Forecasting Inflation" // *IEEE Transactions on Neural Networks*. 2001. № 12 (4). P. 674 – 683.
5. White, Halbert and Jeffrey Racine. "Statistical Inference, The Bootstrap, and Neural-Network Modeling with Application to Foreign Exchange Rates" // *IEEE Transactions on Neural Networks*, 2001. № 12 (4). P. 657 – 673.
6. Hartford, Jason, Greg Lewis, Kevin Leyton-Brown, Matt Taddy. (2016) "Counterfactual Prediction with Deep Instrumental Variables Networks", *arXiv:1612.09596*
7. Farrell Max H., Tengyuan Liang, Sanjog Misra. (2019) "Deep Neural Networks for Estimation and Inference", *arXiv:1809.09953*
8. Dütting, Paul, Zhe Feng, Harikrishna Narasimhan, David C. Parkes. (2017) "Optimal Auctions through Deep Learning", *arXiv:1706.03459*
9. Feng, Guanhao, Jingyu He, Nicholas G. Polson. (2018) "Deep Learning for Predicting Asset Returns", *arXiv:1804.09314*
10. Heaton J.B., Polson N.G., Witte J.H. (2016a) "Deep Learning in Finance", *arXiv:1602.06561*
11. Guoqiang Zhang, B Eddy Patuwo, and Michael Y Hu. *Forecasting with artificial neural networks: The state of the art* // *International journal of forecasting*. 1998. № 14 (1). P. 35 – 62.
12. Osman Abbas. *Neural Networks in Business Forecasting* // *International Journal of Computer (IJC)*. November 2005. <https://www.researchgate.net/publication/295907353>
13. G Peter Zhang and Min Qi. *Neural network forecasting for seasonal and trend time series*. *European journal of operational research*. 2005. № 160 (2). P. 501 – 514.
14. Jahn M *Artificial neural network regression models in a panel setting* // *Predicting economic growth*. September 2020. Vol. 91. P. 148 – 154.
15. Michael Štencl and Jiří Šťastný. *Artificial Neural Networks Numerical Forecasting of Economic Time Series. Artificial Neural Networks – Application*. Publisher InTech, 2011.
16. Wei huang, kin keung lai, yoshiteru nakamori, shouyang wang, lean yu. *neural networks in finance and economics forecasting* // *International Journal of Information Technology & Decision Making*. 2007. Vol. 6. № 1. P. 113 – 140.
17. Tian Guo, Zhao Xu, Xin Yao, Haifeng Chen, Karl Aberer, and Koichi Funaya. *Robust online time series prediction with recurrent neural networks*. In *Data Science and Advanced Analytics (DSAA) 2016* // *IEEE International Conference on Ieee*, 2016. P. 816 – 825.
18. Kasun Bandara, Christoph Bergmeir, and Slawek Smyl. *Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach*. *arXiv preprint arXiv:1710.03222*, 2017.
19. Nikolay Laptev, Jason Yosinski, Li Erran Li, and Slawek Smyl. *Time-series extreme event forecasting with neural networks at uber* // *In International Conference on Machine Learning*. 2017. № 34. P. 1 – 5.

20. Anna Almosova, Niek Andreseny. *Nonlinear Inflation Forecasting with Recurrent Neural Networks*. May 2019.
21. Gabor Petnehazi. *Recurrent Neural Networks for Time Series Forecasting*. arXiv:1901.00069v1 [cs.LG] 1 Jan 2019.
22. Goel, Hardik, Igor Melnyk, Nikunj Oza, Bryan Matthews, Arindam Banerjee. (2016) “Multivariate Aviation Time Series Modeling: VARs vs. LSTMs”, Manuscript
23. Sergiy Verstyuk. *Modeling Multivariate Time Series in Economics: from Auto-Regressions to Recurrent Neural Networks*. 30 April 2020.
24. Mvubu, Mhlasakululeka & Kabuga, Emmanuel & Plitz, Christian & Bah, Bubacarr & Becker, Ronnie & Zimmermann, Hans. (2020). *On Error Correction Neural Networks for Economic Forecasting*
25. Klein L. R., Goldberger A. S. *An econometric model of the United States, 1929-1952*, Amsterdam, 1955.
26. Нейлор Т. и др. *Машинные имитационные эксперименты с моделями экономических систем: пер с англ.* М.: Мир, 1975.
27. Ермилов А.П. *Макроэкономическое прогнозирование в США*. Новосибирск: Наука, Сиб. отд. 1987.
28. Чижов Ю.А. *Модель экономики США*. Новосибирск: Наука, Сиб. отд. 1977. 205 с.
29. Форрестер Дж. *Мировая экономика: пер. с англ.* М.: ООО «Издательство АСТ», 2003.
30. Колмаков И.Б. *Основы моделирования. Имитационные макромоделли рыночной экономики*. М.: Из-во Рос. экон. акад им. Г.В. Плеханова, 1995. 203 с.
31. Лусин В.С., Антипов В.И., Гусев В.Б., Колмаков И.Б., Моторин В.И. *Проблемы моделирования воспроизводства ВВП России*. М.: ТЕИС, 2004.
32. Kavousi-Fard A., Samet H., Marzbani F. *A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting*. *Expert Syst. Appl.* 2014. № 41. P. 6047 – 6056.
33. Nguyen N., Cripps A. *Predicting housing value: a comparison of multiple regression analysis and artificial neural networks* // *JRER*. 2001. Vol. 3. P. 314 – 336.
34. Singh P. *Big data time series forecasting model: a fuzzy-neuro hybridize approach*. *Computational Intelligence for Big Data Analysis*. 2015. P. 55 – 72.
35. Wang J.S., Ning C.X. *ANFIS Based Time Series Prediction Method of Bank Cash Flow Optimized by Adaptive Population Activity PSO Algorithm* // *Information*. 2015. № 6 (3). P. 300 – 313.
36. Kitova O.V., Kolmakov I.B., Dyakonova L.P., Grishina O.A., Sekerin V.D., Danko T.P. *Hybrid intelligent system of forecasting of the socio-economic development of the country* // *Ijaber*. 2016. Vol. 14. № 9. P. 5755 – 5766.
37. Kitova O., Savinova V., Dyakonova L., Kitov V. *Development of hybrid models and a system for forecasting the indicators of the Russian economy* // *Espacios*. 2019. Tom 40. № 10. P. 18.
38. Китова О.В., Савинова В.М., Дьяконова Л.П. *Гибридная интеллектуальная информационная система прогнозирования «СГМ Горизонт» и ее применение в подготовке магистров*. *Международный научный журнал «Современные информационные технологии и ИТ-образование»*, [S.l.], v. 15, n. 4, p. 862-870, dec. 2019. ISSN 2411-1473.
39. Китова О.В., Дьяконова Л.П., Савинова В.М., Китов В.В. *Система поддержки принятия решений «Горизонт» на основе гибридных моделей прогнозирования показателей экономики России* // *Экономика: вчера, сегодня, завтра*. 2018 Том 8. № 9А. С. 309 – 319.
40. Werbos P.J. *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. Ph.D. thesis, Harvard University, Cambridge, MA, 1974.
41. Галушкин А.И. *Синтез многослойных систем распознавания образов*. М.: Энергия, 1974.
42. Rumelhart D.E., Hinton G.E., Williams R.J., *Learning Internal Representations by Error Propagation*. In: *Parallel Distributed Processing*, Cambridge, MA, MIT Press. 1986. Vol. 1. P. 318 – 362.
43. Барцев С.И., Охонин В.А. *Адаптивные сети обработки информации*. Красноярск: Ин-т физики СО АН СССР, 1986. Препринт N 59Б. 20 с
44. Cybenko, George. “Approximation by Superpositions of a Sigmoidal Function” // *Mathematics of Control, Signals, and Systems*. 1989 № 2. P. 303 – 314.
45. Elman J.L. *Finding structure in time* // *Cognitive science*. 1990. Vol. 14. № 2. P. 179 – 211.
46. Brainerd W.S., Landweber L.H. *Theory of Computation*. Wiley, 1974.
47. Sepp Hochreiter; Jürgen Schmidhuber. *Long short-term memory* (англ.) // *Neural Computation* (англ.) русск.: journal. 1997. Vol. 9. №. 8. P. 1735 – 1780. doi:10.1162/neco.1997.9.8.1735. PMID 9377276. Архивировано 26 мая 2015 года. Архивная копия от 26 мая 2015 на Wayback Machine

48. Fernández, Santiago; Graves, Alex; Schmidhuber, Jürgen. *An Application of Recurrent Neural Networks to Discriminative Keyword Spotting* (англ.) // *Proceedings of the 17th International Conference on Artificial Neural Networks : journal*. Berlin, Heidelberg: Springer-Verlag, 2007. Vol. ICANN'07. P. 220 – 229. ISBN 978-3-540-74693-5.

49. Graves Alex; Schmidhuber, Jürgen. *Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks* (англ.) // *Neural Information Processing Systems (NIPS) Foundation : journal / Bengio, Yoshua; Schuurmans, Dale; Lafferty, John; Williams, Chris editor-K. I.; Culotta, Aron*. 2009. P. 545 – 552.

50. Bo Fan, Lijuan Wang, Frank K. Soong, and Lei Xie (2015). *Photo-Real Talking Head with Deep Bidirectional LSTM*. In *Proceedings of ICASSP 2015*.

51. Sutskever L., Vinyals O., Le Q. *Sequence to Sequence Learning with Neural Networks* (неопр.) // *Electronic Proceedings of the Neural Information Processing Systems Conference*. 2014. Том 27.

52. Zhengping Che, Sanjay Purushotham, Kyunghyun Cho, David Sontag, and Yan Liu. *Recurrent neural networks for multivariate time series with missing values*. *Scientific reports*. 2018. № 8 (1). P. 6085.

53. Колмаков И.Б., Доможаков М.В., *Методология прогнозирования показателей сферы научных исследований и инноваций с помощью нейронных сетей // Управленческие науки*. 2017. Том 7. № 1. С. 53 – 62.

### References

1. Fjodor van Veen. *The neural network zoo*. 2016. <https://www.asimovinstitute.org/neural-network-zoo/>
2. Sajmon Hajkin. *Нейронные сети: полный курс = Neural Networks: A Comprehensive Foundation*. 2-е изд. М.: «Вил'ямс», 2006.
3. Swanson, Norman R., and Halber White. “A Model Selection Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks”. *Review of Economics and Statistics*. 1997. № 79 (4). P. 540 – 550.
4. Chen, Xiaohong, Jeffrey Racine, and Norman R. Swanson. “Semiparametric ARX Neural Network Models with an Application to Forecasting Inflation”. *IEEE Transactions on Neural Networks*. 2001. № 12 (4). P. 674 – 683.
5. White, Halbert and Jeffrey Racine. “Statistical Inference, The Bootstrap, and Neural-Network Modeling with Application to Foreign Exchange Rates”. *IEEE Transactions on Neural Networks*, 2001. № 12 (4). P. 657 – 673.
6. Hartford, Jason, Greg Lewis, Kevin Leyton-Brown, Matt Taddy. (2016) “Counterfactual Prediction with Deep Instrumental Variables Networks”, *arXiv:1612.09596*
7. Farrell Max H., Tengyuan Liang, Sanjog Misra. (2019) “Deep Neural Networks for Estimation and Inference”, *arXiv:1809.09953*
8. Dütting, Paul, Zhe Feng, Harikrishna Narasimhan, David C. Parkes. (2017) “Optimal Auctions through Deep Learning”, *arXiv:1706.03459*
9. Feng, Guanhao, Jingyu He, Nicholas G. Polson. (2018) “Deep Learning for Predicting Asset Returns”, *arXiv:1804.09314*
10. Heaton J.B., Polson N.G., Witte J.H. (2016a) “Deep Learning in Finance”, *arXiv:1602.06561*
11. Guoqiang Zhang, B Eddy Patuwo, and Michael Y Hu. *Forecasting with artificial neural networks: The state of the art*. *International journal of forecasting*. 1998. № 14 (1). P. 35 – 62.
12. Osman Abbas. *Neural Networks in Business Forecasting*. *International Journal of Computer (IJC)*. November 2005. <https://www.researchgate.net/publication/295907353>
13. G Peter Zhang and Min Qi. *Neural network forecasting for seasonal and trend time series*. *European journal of operational research*. 2005. № 160 (2). P. 501 – 514.
14. Jahn M *Artificial neural network regression models in a panel setting. Predicting economic growth*. September 2020. Vol. 91. P. 148 – 154.
15. Michael Štencl and Jiří Šťastný. *Artificial Neural Networks Numerical Forecasting of Economic Time Series*. *Artificial Neural Networks – Application*. Publisher InTech, 2011.
16. Wei huang, kin keung lai, yoshiteru nakamori, shouyang wang, lean yu. *neural networks in finance and economics forecasting*. *International Journal of Information Technology & Decision Making*. 2007. Vol. 6. № 1. P. 113 – 140.
17. Tian Guo, Zhao Xu, Xin Yao, Haifeng Chen, Karl Aberer, and Koichi Funaya. *Robust online time series prediction with recurrent neural networks*. In *Data Science and Advanced Analytics (DSAA) 2016*. *IEEE International Conference on Ieee*, 2016. P. 816 – 825.
18. Kasun Bandara, Christoph Bergmeir, and Slawek Smyl. *Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach*. *arXiv preprint arXiv:1710.03222*, 2017.

19. Nikolay Laptev, Jason Yosinski, Li Erran Li, and Slawek Smyl. *Time-series extreme event forecasting with neural networks at uber*. In *International Conference on Machine Learning*. 2017. № 34. P. 1 – 5.
20. Anna Almosova, Niek Andreseny. *Nonlinear Inflation Forecasting with Recurrent Neural Networks*. May 2019.
21. Gabor Petnehazi. *Recurrent Neural Networks for Time Series Forecasting*. arXiv:1901.00069v1 [cs.LG] 1 Jan 2019.
22. Goel, Hardik, Igor Melnyk, Nikunj Oza, Bryan Matthews, Arindam Banerjee. (2016) “Multivariate Aviation Time Series Modeling: VARs vs. LSTMs”, Manuscript
23. Sergiy Verstyuk. *Modeling Multivariate Time Series in Economics: from Auto-Regressions to Recurrent Neural Networks*. 30 April 2020.
24. Mvubu, Mhlasakululeka & Kabuga, Emmanuel & Plitz, Christian & Bah, Bubacarr & Becker, Ronnie & Zimmermann, Hans. (2020). *On Error Correction Neural Networks for Economic Forecasting*
25. Klein L. R., Goldberger A. S. *An econometric model of the United States, 1929-1952*, Amsterdam, 1955.
26. Nejlor T. i dr. *Mashinnye imitacionnye jeksperimenty s modeljami jekonomicheskikh sistem: per s angl. M.: Mir, 1975*.
27. Ermilov A.P. *Makrojekonomicheskoe prognozirovanie v SShA*. Novosibirsk: Nauka, Sib. otd. 1987.
28. Chizhov Ju.A. *Model' jekonomiki SShA*. Novosibirsk: Nauka, Sib. otd. 1977. 205 s.
29. Forrester Dzh. *Mirovaja jekonomika: per. s angl. M.: OOO «Izdatel'stvo AST», 2003*.
30. Kolmakov I.B. *Osnovy modelirovaniya. Imitacionnye makromodeli rynochnoj jekonomiki. M.: Iz-vo Ros. jekon. akad im. G.V. Plehanova, 1995. 203 s.*
31. Lisin V.S., Antipov V.I., Gusev V.B., Kolmakov I.B., Motorin V.I. *Problemy modelirovaniya vosproizvodstva VVP Rossii. M.: TEIS, 2004*.
32. Kavousi-Fard A., Samet H., Marzbani F. *A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting*. *Expert Syst. Appl.* 2014. № 41. P. 6047 – 6056.
33. Nguyen N., Cripps A. *Predicting housing value: a comparison of multiple regression analysis and artificial neural networks // JRER. 2001. Vol. 3. P. 314 – 336*.
34. Singh P. *Big data time series forecasting model: a fuzzy-neuro hybridize approach. Computational Intelligence for Big Data Analysis. 2015. P. 55 – 72*.
35. Wang J.S., Ning C.X. *ANFIS Based Time Series Prediction Method of Bank Cash Flow Optimized by Adaptive Population Activity PSO Algorithm. Information. 2015. № 6 (3). P. 300 – 313*.
36. Kitova O.V., Kolmakov I.B., Dyakonova L.P., Grishina O.A., Sekerin V.D., Danko T.P. *Hybrid intelligent system of forecasting of the socio-economic development of the country. Ijaber. 2016. Vol. 14. № 9. P. 5755 – 5766*.
37. Kitova O., Savinova V., Dyakonova L., Kitov V. *Development of hybrid models and a system for forecasting the indicators of the Russian economy. Espacios. 2019. Tom 40. № 10. P. 18*.
38. Kitova O.V., Savinova V.M., D'jakonova L.P. *Gibridnaja intellektual'naja informacionnaja sistema prognozirovaniya «SGM Gorizont» i ee primenenie v podgotovke magistrrov. Mezhdunarodnyj nauchnyj zhurnal «Sovremennye informacionnye tehnologii i IT-obrazovanie», [S.l.], v. 15, n. 4, p. 862-870, dec. 2019. ISSN 2411-1473*.
39. Kitova O.V., D'jakonova L.P., Savinova V.M., Kitov V.V. *Sistema podderzhki priyatija reshenij «Gorizont» na osnove gibridnyh modelej prognozirovaniya pokazatelej jekonomiki Rossii. Jekonomika: vchera, segodnja, zavtra. 2018 Tom 8. № 9A. S. 309 – 319*.
40. Werbos P.J. *Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University, Cambridge, MA, 1974*.
41. Galushkin A.I. *Sintez mnogoslojnyh sistem raspoznavaniya obrazov. M.: Jenergija, 1974*.
42. Rumelhart D.E., Hinton G.E., Williams R.J., *Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing, Cambridge, MA, MIT Press. 1986. Vol. 1. P. 318 – 362*.
43. Barcev S.I., Ohonin V.A. *Adaptivnye seti obrabotki informacii. Krasnojarsk: In-t fiziki SO AN SSSR, 1986. Preprint N 59B. 20 s*
44. Cybenko, George. “Approximation by Superpositions of a Sigmoidal Function”. *Mathematics of Control, Signals, and Systems. 1989 № 2. P. 303 – 314*.
45. Elman J.L. *Finding structure in time. Cognitive science. 1990. Vol. 14. № 2. P. 179 – 211*.
46. Brainerd W.S., Landweber L.H. *Theory of Computation. Wiley, 1974*.
47. Sepp Hochreiter; Jürgen Schmidhuber. *Long short-term memory (angl.). Neural Computation (angl.) russk.: journal. 1997. Vol. 9. №. 8. P. 1735 – 1780. doi:10.1162/neco.1997.9.8.1735. PMID 9377276. Arhivirovano 26 maja 2015 goda. Arhivnaja kopija ot 26 maja 2015 na Wayback Machine*

48. Fernández, Santiago; Graves, Alex; Schmidhuber, Jürgen. *An Application of Recurrent Neural Networks to Discriminative Keyword Spotting (angl.)*. *Proceedings of the 17th International Conference on Artificial Neural Networks : journal*. Berlin, Heidelberg: Springer-Verlag, 2007. Vol. ICANN'07. P. 220 – 229. ISBN 978-3-540-74693-5.

49. Graves Alex; Schmidhuber, Jürgen. *Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks (angl.)*. *Neural Information Processing Systems (NIPS) Foundation : journal / Bengio, Yoshua; Schuurmans, Dale; Lafferty, John; Williams, Chris editor-K. I.; Culotta, Aron*. 2009. P. 545 – 552.

50. Bo Fan, Lijuan Wang, Frank K. Soong, and Lei Xie (2015). *Photo-Real Talking Head with Deep Bidirectional LSTM*. In *Proceedings of ICASSP 2015*.

51. Sutskever L., Vinyals O., Le Q. *Sequence to Sequence Learning with Neural Networks (neopr.)*. *Electronic Proceedings of the Neural Information Processing Systems Conference*. 2014. Tom 27.

52. Zhengping Che, Sanjay Purushotham, Kyunghyun Cho, David Sontag, and Yan Liu. *Recurrent neural networks for multivariate time series with missing values*. *Scientific reports*. 2018. № 8 (1). P. 6085.

53. Kolmakov I.B., Domozhakov M.V., *Metodologija prognozirovanija pokazatelej sfery nauchnyh issledovanij i innovacij s pomoshh'ju nejronnyh setej*. *Upravlencheskie nauki*. 2017. Tom 7. № 1. S. 53 – 62.

## APPLICATION OF NEURAL NETWORKS FOR PREDICTING SOCIO-ECONOMIC TIME SERIES

*Kitova O.V., Doctor of Economic Sciences (Advanced Doctor), Associate Professor,  
Dyakonova L.P., Candidate of Physical and Mathematical Sciences (Ph.D.), Associate Professor,  
Kitov V.A., Candidate of Engineering Sciences (Ph.D.), Senior Research Officer,  
Savinova V.M., Senior Lecturer,  
Plekhanov Russian University of Economics*

**Abstract:** the purpose of the study is to justify the choice of artificial neural network architectures for inclusion in the neural network module of the hybrid short-term forecasting system “SGM Horizon” developed by the authors. The hybrid model system and the SGM Horizon software package are designed to forecast macroeconomic indicators at the country and regional level. The hybrid approach ensures that the required quality of forecasts is achieved for the entire indicator system. Neural network models play a key role here. The article provides an overview of the work on the use of neural networks in forecasting, with special attention paid to research in the field of forecasting economic time series. The methodological basis of the research is a hybrid approach that includes machine learning models, such as neural networks and decision trees, along with econometric models. Two basic architectures are used for predicting economic indicators based on neural networks: direct distribution networks and recurrent networks. In direct propagation networks, a multi – layer perceptron is used to predict time series; in recurrent networks, a network architecture with long-term and short-term memory (LSTM) is used. Based on the analysis of tools for solving modeling problems based on neural networks, the functions of the C++ and C# FANN (Fast Artificial Neural Network) library were used for their implementation in SGM Horizon. Within the framework of SGM Horizon, a module of Artificial neural networks has been developed that allows time series forecasting based on multi-layer perceptron architectures and recurrent networks with long-and short-term memory (LSTM). The forecast of indicators of macroeconomics, state budgets, the social sphere and foreign economic activity of the Russian Federation is carried out in the “SGM Horizon” system. At the first stage, the system predicts all indicators based on a regression model. As a result, out of a total of 175 indicators, high accuracy and quality values were obtained for 125 indicators. At the second stage, neural network predictive models were built for the remaining 50 indicators using the neural network module. Results of satisfactory accuracy were obtained for 45 indicators. The hybrid approach to modeling and forecasting of socio-economic indicators of the Russian Federation developed by the authors makes it possible to achieve high accuracy of the forecast for the entire set of indicators under study. The forecasting of indicators of macroeconomics, state budgets, social sphere and foreign economic activity of the Russian Federation carried out in the SGM Horizon system demonstrates the effectiveness of this approach. Calculations based on the multi-layer perceptron architecture for predicting 45 out of 50 indicators gave more accurate forecasts compared to the basic regression model.

**Keywords:** artificial neural networks, socio-economic indicators of the Russian Federation, forecasting, time series, hybrid information and analytical system