

МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра математической кибернетики и компьютерных наук

**ПОСТРОЕНИЕ МОДЕЛЕЙ СИСТЕМНОЙ ДИНАМИКИ С
ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ**

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 273 группы
направления 02.04.03 — Математическое обеспечение и администрирование
информационных систем
факультета КНиИТ
Толобаева Игоря Олеговича

Научный руководитель
профессор, д. т. н., доцент

А. С. Богомолов

Заведующий кафедрой
к. ф.-м. н., доцент

С. В. Миронов

Саратов 2022

ВВЕДЕНИЕ

Целью выпускной квалификационной работы (ВКР) является разработка программных средств для построения моделей системной динамики с использованием нейронных сетей.

Поставленная цель определяет следующие задачи:

- поиск, перевод и анализ результатов современных международных научных публикаций, посвященных разработке математических моделей системной динамики, в частности, с использованием нейронных сетей;
- уточнение предметной области и построение варианта модели системной динамики основных экономических показателей государств в связи с развитием водородной энергетики;
- обзор и выбор инструментов решения задачи;
- введение и использование для развития модели аппарата на основе нейронных сетей;
- разработка, программная реализация и тестирование программного средства.

1 Модель системной динамики

1.1 Применение методов машинного обучения в системной динамике

Вычислительный интеллект (ВИ) — это область исследования, в которой используются вычислительные методы для имитации адаптации, обучения и эволюции, которые встречаются в природных явлениях. Область ВИ включает три основные парадигмы: искусственные нейронные сети (ИНС), которые черпают вдохновение из нейронных сетей в биологическом мозге; эволюционные вычисления (ЕС), вдохновленные принципами дарвиновской эволюции живой природы и социального поведения; и нечеткие системы (FS), которые отражают человеческое мышление с использованием неточных лингвистических терминов [1].

Типичная архитектура ИНС состоит из нескольких слоев, каждый из которых состоит из нескольких элементов (нейронов). Типичная ИНС состоит из входного слоя, скрытого слоя (или слоев) и выходного слоя. В зависимости от топологии сети ИНС подразделяются на три основных типа: FFNN [2]; RNN [3]; и самоорганизующиеся карты [4]. Для обучения сетей FFNN и RNN применяется обучение с учителем, в то время как для SOM применяется обучение без учителя. Обучение с подкреплением находится между обучением с учителем и обучением без учителя. ИНС используются для нескольких целей, таких как аппроксимация функций [5], распознавание образов [6], прогнозирование и классификация [7, 8]. Сеть радиальных базисных функций (RBFN), долговременная память (LSTM) [9] и ESN [10] являются наиболее известными моделями ИНС.

В последние годы были предприняты заметные усилия в контексте принятия различных методов ВИ для поддержки процесса моделирования СД.

1.2 Проблемы применения методов вычислительного интеллекта

Несмотря на все описанные усилия по поддержке этапов СД-моделирования, применение методов ВИ было ограничено конкретными этапами процесса моделирования, при этом большее внимание уделялось этапам оценки параметров модели, предсказанию и выдаче советов. Применение же этих методов для вывода концептуальных и формальных моделей (часто представленных ДПСС и ДП соответственно) или лежащих в основе математических

уравнений встречается редко. Проблемы, связанные с применением подходов, основанных на данных, в частности ВИ, можно резюмировать следующим образом:

- При создании структур моделей, представленных как ДПСС и ДП, применяемые методы ВИ требуют типичных шагов преобразования этих моделей в соответствующую имитационную модель, чтобы можно было оценить их производительность. Эти дополнительные затраты требуют слишком много времени и поэтому ограничивают возможность быстрой проверки большого количества получаемых моделей.
- Большинство предлагаемых алгоритмов требуют наблюдения для всех системных переменных, что может быть дополнительным ограничением в случаях, когда такие наблюдения недоступны.
- Существующие исследования в основном ограничивают сравнение своих вычисленных моделей целевыми моделями для проверки на основе результатов моделирования. Структурное сравнение предполагаемых моделей в основном отсутствует, и почти не существует руководства по выполнению задачи подобного рода.
- Не существует структуры или методологии, позволяющей создавать эти фазы моделирования обобщенным способом, который обеспечивает систему сквозной поддержки для процесса моделирования. Это может быть связано с трудностью применения таких методов для этого процесса, во многом зависящего от разработчика модели.

2 Подбор параметров модели системной динамики

2.1 Построение модели системной динамики

В предлагаемой концепции модели системной динамики включают комплексы причинно-следственных схем, графов и уравнений, связывающих оцениваемый уровень развития водородной энергетики страны и основные показатели экономического развития стран. Основным объектом для отображения причинно-следственных связей является таблица G , строки которой соответствуют системным переменным, а столбцы — системным переменным и внешним факторам. Каждой клетке G соответствует функция

$G_{ij}(Y_1(t), \dots, Y_m(t), t)$, множество переменных которой может пересекаться с множеством системных переменных, внешних факторов и переменных среды. Функции $G_{ij}(Y_1(t), \dots, Y_m(t), t)$ принимают значения на множестве $0, 1, -1$ и показывают влияние переменной или фактора из столбца на переменную из строки при условиях, заданных переменными $Y_1(t), \dots, Y_m(t)$: «1» — вызывает рост, значение «-1» — вызывает снижение, значение 0 — влияние не учитывается в этой модели. Множество значений функций $G_{ij}(Y_1(t), \dots, Y_m(t), t)$ может также и иным (множество лингвистических значений, например).

Рассмотрим такую структуру для ФРГ. В качестве основных экономических показателей были выбраны величины, характеризующие:

$X_1(t)$ — ВВП;

$X_2(t)$ — Ожидаемая продолжительность жизни при рождении;

$X_3(t)$ — Экономические показатели — оценка (IMD);

$X_4(t)$ — Производительность труда;

$X_5(t)$ — Human Capital Index;

$X_6(t)$ — Экспорт товаров;

$X_7(t)$ — Борьба с коррупцией;

$X_8(t)$ — Валовой национальный доход;

$X_9(t)$ — Промышленное производство;

$X_{10}(t)$ — Производство автомобилей в год;

В таблице 1 значение «+» означает, что рост показателей в столбце вызывает рост показателей в строке, «-» — вызывает понижение, «0» — непосредственное влияние в этом значении схемы не рассматривается, «?» — влияние переменное. Аргумент времени при $X_1(t), \dots, X_{10}(t)$ в таблице опущен для краткости записи.

Таблица 1 – Динамическая причинно-следственная схема связей комплексных показателей развития страны и влияния на них степени развития водородной энергетики государства на рассматриваемом временном интервале

	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}
X_1 – ВВП	0	+	+	+	+	+	-	+	-	?	+
X_2 – Ожидаемая продолжительность жизни при рождении	+	0	+	+	0	0	-	+	+	+	0
X_3 – Экономические показатели - оценка (IMD)	+	+	0	+	+	-	-	+	-	+	+
X_4 – Производительность труда	+	+	+	0	+	0	-	0	-	+	0
X_5 – Human Capital Index	+	+	+	+	0	+	-	0	-	+	+
X_6 – Экспорт товаров	+	+	+	+	+	0	0	+	+	+	+
X_7 – Борьба с коррупцией	-	-	-	0	-	+	0	+	+	+	+
X_8 – Валовой национальный доход	+	+	+	+	+	+	-	0	-	+	+
X_9 – Промышленное производство	-	-	-	-	-	+	+	-	0	-	+
X_{10} – Производство автомобилей в год	+	+	+	+	+	+	-	+	-	0	+

На основе такой схемы для рассматриваемого интервала времени строится система уравнений для переменных $X_1(t)$ – $X_{10}(t)$. Переменная $X_{11}(t)$, которая рассматривается как внешний фактор, входит в правые части этих уравнений. В соответствии с принципами системной динамики, уравнения в данном случае имеют вид:

$$\begin{cases} X_1(t+1) - X_1(t) = \Pi_i^+(t)X_{11 \rightarrow 1}^+(t) - \Pi_i^-(t)X_{11 \rightarrow 1}^-(t) \\ \dots \\ X_{10}(t+1) - X_{10}(t) = \Pi_i^+(t)X_{11 \rightarrow 10}^+(t) - \Pi_i^-(t)X_{11 \rightarrow 10}^-(t) \end{cases}$$

где $\Pi_i^+(t)$ – произведение переменных системы, рост каждой из которых в соответствии с предполагаемыми причинно-следственными связями увеличивает $X_i(t)$; $\Pi_i^-(t)$ – произведение переменных системы, рост которых уменьшает $X_i(t)$; $\Pi_{11 \rightarrow i}^+ = X_{11}(t)$, если рост $X_{11}(t)$ вызывает рост $X_i(t)$, иначе $X_i^+(t) = 1$, $X_{11 \rightarrow i}^-(t) = X_{11}(t)$, если рост $X_{11}(t)$ вызывает уменьшение $X_i(t)$, иначе $X_{11 \rightarrow i}^-(t) = 1$, $i = 1, \dots, 10$. Соответственно, если прямое влияние $X_{11}(t)$ на $X_i(t)$ в модели не рассматривается, то $X_{11 \rightarrow i}^-(t) = X_{11 \rightarrow i}^+(t) = 1$.

Требуемые или ориентировочные значения $X_1^*(t), \dots, X_n^*(t)$ фигурирующие в (1), могут быть определены для моделирования или принятия решений при анализе предшествующих благоприятных периодов развития страны, которые не были связаны с усилением геополитической конфронтации и развитием пандемии COVID-19. Например, в качестве такого периода можно рассматривать промежутки времени до 2014 года и наступивших последующих санкций

США, которые неблагоприятно действовали на все страны Европы. Также значения $X_1^*(t), \dots, X_n^*(t)$ могут определяться из конкурентных соображений.

Влияние пандемии следует учитывать в рассматриваемой модели при определении или оценке значений $a(t)$ — вектора параметров среды. Это влияние негативно сказывается на развитии водородной энергетики, как и на всей энергетической промышленности и, кроме того, вызывает дополнительную нехватку ресурсов для ее развития. В вариациях моделей системной динамики, которые будут строиться в предлагаемой концепции, пандемия может быть также введена и как внешний фактор.

Математическое обеспечение, основанное на предлагаемой концепции, может быть применено при разработке систем поддержки принятия решений. Такие системы будут использоваться в работе экспертных групп при ЛПР различного уровня для генерирования и анализа различных сценариев развития проблемных ситуаций, в тренинговых комплексах и научных исследованиях. При этом исследуемые сценарии могут носить как прогностический характер, так и касаться прошлых событий, варианты развития которых представляют интерес для исследования причин того или иного явления.

2.2 Прогнозирование с использованием классических методов

Был рассмотрен подбор параметров с использованием восьми методов из пакета *scipy* без применения дополнительных ограничений: Метод Нелдера-Мида (Nelder-Mead), Метод Пауэлла (Powell), Метод сопряженных градиентов (CG), Алгоритм Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS), L-BFGS-B, Усеченные методы Ньютона (TNC), Оптимизация с ограничениями посредством линейного приближения (COBYLA) и Последовательное квадратичное программирование (SLSQP). Данные методы были выбраны по причине того, что не требуют якобиан в качестве обязательного входного параметра и представляют собой широкий спектр различных подходов к оптимизации функции.

Результаты минимизации функции потерь представлены в таблице 2. Как видно из таблицы, наилучший результат был достигнут с использованием алгоритма Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS).

2.3 Прогнозирование с использованием нейронных сетей

Статистические модели действительно часто применяются для прогнозирования временных рядов. Однако у этих методов есть большое число огра-

Таблица 2 – Сравнение результатов минимизации функции потерь с помощью различных методов

Название метода	Значение ошибки
Nelder-Mead	7.50
Powell	22.00
CG	3.50
BFGS	2.65
L-BFGS-B	3.91
TNC	4.90
COBYLA	33.46
SLSQP	3.35

ничений:

- Они чувствительны к отсутствующим данным;
- Обычно работают лишь с одномерными наборами данных и с трудом могут быть применены к многомерным наборам данных;
- Для их обучения нужны полные данные. Некоторые пропущенные значения могут привести к очень плохому результату модели.

Методы глубокого обучения способны справиться с вышеперечисленными проблемами так как они:

- Не чувствительны к отсутствующему значению;
- В них просто включить экзогенные переменные (применимо как к одномерному набору данных, так и к многомерному набору данных);
- Способны обнаружить нелинейные взаимодействия характеристик;
- Поддерживают автоматическое извлечение признаков.

2.3.1 Нейронные сети с долгой краткосрочной памятью

LSTM впервые были представлены в 1997 году как усовершенствованный алгоритм RNN. LSTM являются расширением более ранних RNN, способных сохранять долговременную память и использовать ее для изучения закономерностей в длинных последовательностях исходных данных. До появления LSTM рекуррентные нейронные сети могли иметь память, но только о тех этапах процесса, которые происходили в их ближайшем прошлом. LSTM, напротив, вводит циклы, которые могут генерировать длительные градиенты и удерживать в памяти долгосрочные паттерны, которые сеть обнаруживает во время прохождения циклов.

Шлюзы выполняют матричные перемножения между значениями информации, которые они получают в качестве текущих входов из кратковременной

или долговременной памяти. Со временем LSTM узнает, какие части информации эффективны для уменьшения ошибки предсказания. Сеть будет открывать и закрывать шлюзы, присваивая значениям информации большие или меньшие веса от 0 до 1. Через свои циклы она пропускает полезные значения с большими весами через выходной шлюз для формирования новой кратковременной памяти, а значения с малыми весами отбрасывает [11].

LSTM таким образом состоит из четырех основных компонентов: входной шлюз, выходной шлюз, ячейка памяти и шлюз забывания.

- Входной шлюз: контролирует добавление информации в состояние ячейки. Другими словами, входной шлюз будет рассматривать, какая информация должна быть добавлена в состояние ячейки, чтобы обеспечить добавление важной информации, а не избыточной информации или шума.
- Ячейка памяти: (1) контролирует значение, которое может быть удалено или обновлено (2) содержит значение, которое может быть необходимо сохранить в качестве дополнительной информации для других временных шагов.
- Выходной шлюз: управляет выбором полезной обучающей информации из текущего состояния ячейки в качестве выходного сигнала.
- Шлюз забывания: управляет удалением из состояния ячейки информации, которая больше не требуется для обучения LSTM или менее важна. Это помогает оптимизировать производительность сети LSTM.

2.3.2 Датасет

В качестве исходных данных для модели были использованы временные ряды тех экономических показателей модели, для которых частота измерения составляет один месяц либо один квартал. Из-за больших объемов данных использование классических методов системной динамики для подобных данных становится нецелесообразно. Нейронные сети же напротив способны добиться большей предсказательной силы именно на больших объемах данных.

Для обеспечения однородности данных временные ряды экономических показателей, имеющих частоту измерения один квартал, были искусственным образом расширены в четыре раза, что позволило ввести одинаковый формат данных для всего датасета.

В датасет вошли такие показатели как Валовой внутренний продукт,

Производительность труда, Экспорт товаров и Промышленное производство.

2.3.3 Метод Холта-Винтерса

Для получения более репрезентативных результатов данные были предварительно сглажены с помощью метода Холта-Винтерса.

Метод Холта-Уинтерса — это распространенная процедура прогнозирования временных рядов, способная учитывать как их тренд, так и сезонность. Сам метод Холта-Уинтерса представляет собой комбинацию трех других гораздо более простых компонентов, все из которых являются методами сглаживания:

- Простое экспоненциальное сглаживание (SES).
- Экспоненциальное сглаживание Холта (HES).
- Экспоненциальное сглаживание Винтерса (WES).

По этой причине метод Холта-Винтерса часто называют тройным экспоненциальным сглаживанием, поскольку это буквально комбинация трех методов сглаживания, построенных друг над другом.

2.3.4 Обучение модели

Из-за временных зависимостей в данных временного ряда оказывается сложно полагаться на обычные методы валидации. Чтобы избежать необъективных оценок, следует убедиться, что обучающие наборы содержат наблюдения, которые произошли до тех, которые находятся в проверочных наборах. Возможным способом преодоления этой проблемы является использование алгоритма скользящего окна.

Если задача состоит в прогнозе на следующие n временных шагов, возможно применить процедуру перекрестной валидации для $1, 2, \dots, n$ шагов вперед. Таким образом, возможно также сравнить качество прогнозов для различных временных пределов.

Выбрав лучшую модель, становится возможно обучить ее под весь обучающий набор и оценить ее производительность на отдельном тестовом наборе в последующее время. Оценка производительности может быть выполнена с помощью той же техники скользящего окна, которая используется для перекрестной валидации, но без повторной оценки параметров модели.

Для обучения модели в качестве функции потерь была использована среднеквадратичная ошибка регрессии, которая может быть вычислена по фор-

муле:

$$\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2,$$

где x_i — исходный массив, а y_i — результат предсказания.

LSTM чувствительны к масштабу входных данных. Поэтому на этапе предварительной обработки был применен класс `MinMaxScaler` из модуля `scikit-learn` для нормализации/ремасштабирования набора данных.

Датасет был предварительно разделен на две выборки: 2/3 для обучения и 1/3 для тестирования. Это значит, что полученные поднаборы будут иметь нулевое пересечение классовых меток. В качестве оптимизационного алгоритма был выбран Adam (adaptive moment estimation). Он сочетает в себе и идею накопления движения и идею более слабого обновления весов для типичных признаков.

Количество эпох было установлено на значение в 3000.

Результатом обучения стала модель, которая затем была использована для восстановления исходного временного ряда.

2.4 Модель системной динамики с использованием нейронных сетей

В качестве итогового программного комплекса позволяющего на отрезке времени $[t_0, t_k]$ определить управляющие воздействия, минимизирующие описанный выше функционал были рассмотрены методы, представленные в бесплатной библиотеке для *Python* с открытым исходным кодом *scipy*.

В качестве временных рядов основных экономических показателей были использованы данные с сайтов *knoema.com* и *cleanenergywire.org* за 2000–2019 года. Все показатели при этом были предварительно нормализованы в интервале от 0 до 1, где 0 соответствует минимальному значению за указанный период, а 1 — максимальному.

За начальное приближение в каждом из методов использовался нулевой вектор размера n^2 , где n — количество рассматриваемых экономических показателей.

Временные ряды, полученные на предыдущем этапе, были предварительно приведены в единый с остальными данными формат. Их точность была снижена до одного значения в год, при этом таковое было принято среднее арифметическое значений за год.

Как видно, подбираемые коэффициенты применяются только при вычислении временных рядов, значения которых не были получены с помощью предыдущей модели нейронной сети (массив *static*).

Так как из всех рассмотренных алгоритмов наилучшие результаты были достигнуты с использованием алгоритма Бroyдена-Флетчера-Гольдфарба-Шанно было принято решение об использовании этого алгоритма для минимизации полученной функции ошибки.

Построенная с использованием алгоритма Бroyдена-Флетчера-Гольдфарба-Шанно система уравнений имеет следующий вид:

$$\left\{ \begin{array}{l} X_1(t+1) = (-0.37 + 1) * X_1(t) + (-0.35) * X_2(t) + (-0.30) * X_3(t) + (0.10) * X_4(t) + (-0.47) * X_5(t) + (0.07) * X_6(t) + \\ (0.95) * X_7(t) + (0.66) * X_8(t) + (0.26) * X_9(t) + (-0.26) * X_{10}(t) + (-0.29) * X_{11}(t) \\ X_2(t+1) = (-0.05) * X_1(t) + (0.22 + 1) * X_2(t) + (-0.23) * X_3(t) + (0.03) * X_4(t) + (-0.28) * X_5(t) + (-0.42) * X_6(t) + \\ (0.47) * X_7(t) + (0.26) * X_8(t) + (0.23) * X_9(t) + (0.07) * X_{10}(t) + (-0.29) * X_{11}(t) \\ X_3(t+1) = (-0.08) * X_1(t) + (-0.00) * X_2(t) + (0.45 + 1) * X_3(t) + (-0.23) * X_4(t) + (-0.39) * X_5(t) + (0.71) * X_6(t) + \\ (-0.01) * X_7(t) + (-0.25) * X_8(t) + (-0.12) * X_9(t) + (-0.25) * X_{10}(t) + (0.02) * X_{11}(t) \\ X_4(t+1) = (0.43) * X_1(t) + (-0.12) * X_2(t) + (0.09) * X_3(t) + (-0.06 + 1) * X_4(t) + (0.45) * X_5(t) + (-0.27) * X_6(t) + \\ (-0.13) * X_7(t) + (-0.23) * X_8(t) + (-0.12) * X_9(t) + (0.10) * X_{10}(t) + (0.07) * X_{11}(t) \\ X_5(t+1) = (-0.18) * X_1(t) + (0.23) * X_2(t) + (0.75) * X_3(t) + (0.12) * X_4(t) + (-0.71 + 1) * X_5(t) + (0.01) * X_6(t) + \\ (-0.14) * X_7(t) + (0.51) * X_8(t) + (0.10) * X_9(t) + (-0.60) * X_{10}(t) + (-0.46) * X_{11}(t) \\ X_6(t+1) = (-0.12) * X_1(t) + (-0.10) * X_2(t) + (-0.17) * X_3(t) + (0.26) * X_4(t) + (-0.17) * X_5(t) + (-0.46 + 1) * X_6(t) + \\ (0.25) * X_7(t) + (0.70) * X_8(t) + (0.04) * X_9(t) + (-0.03) * X_{10}(t) + (-0.28) * X_{11}(t) \\ X_7(t+1) = (0.05) * X_1(t) + (-0.02) * X_2(t) + (-0.03) * X_3(t) + (-0.34) * X_4(t) + (0.00) * X_5(t) + (0.60) * X_6(t) + \\ (0.26 + 1) * X_7(t) + (-0.69) * X_8(t) + (-0.06) * X_9(t) + (0.21) * X_{10}(t) + (0.14) * X_{11}(t) \\ X_8(t+1) = (0.13) * X_1(t) + (0.65) * X_2(t) + (-0.51) * X_3(t) + (-0.17) * X_4(t) + (-0.29) * X_5(t) + (-0.48) * X_6(t) + \\ (0.86) * X_7(t) + (-0.20 + 1) * X_8(t) + (0.25) * X_9(t) + (-0.04) * X_{10}(t) + (0.00) * X_{11}(t) \\ X_9(t+1) = (0.12) * X_1(t) + (-0.01) * X_2(t) + (0.62) * X_3(t) + (0.13) * X_4(t) + (-0.41) * X_5(t) + (0.86) * X_6(t) + \\ (-0.80) * X_7(t) + (-0.42) * X_8(t) + (-0.32 + 1) * X_9(t) + (-0.23) * X_{10}(t) + (0.01) * X_{11}(t) \\ X_{10}(t+1) = (0.10) * X_1(t) + (0.08) * X_2(t) + (0.17) * X_3(t) + (-0.20) * X_4(t) + (-0.76) * X_5(t) + (-0.22) * X_6(t) + \\ (0.46) * X_7(t) + (0.12) * X_8(t) + (0.30) * X_9(t) + (0.06 + 1) * X_{10}(t) + (-0.53) * X_{11}(t) \\ X_{11}(t+1) = (0.20) * X_1(t) + (0.01) * X_2(t) + (0.07) * X_3(t) + (-0.01) * X_4(t) + (-0.18) * X_5(t) + (0.38) * X_6(t) + \\ (0.56) * X_7(t) + (-0.33) * X_8(t) + (-0.06) * X_9(t) + (-0.61) * X_{10}(t) + (0.03 + 1) * X_{11}(t) \end{array} \right.$$

Данные по каждой переменной нормировались по формуле $X_{norm} = (X - X_{min}) / (X_{max} - X_{min})$, где X – значение переменной $X_i(t)$, X_{max} , X_{min} – максимальное и минимальное значения в ряду данных по этой переменной.

Как видно из графиков, модельное решение в целом совпадает по тенденции с имеющими данными. Количественная оценка точности построенной модели для всех переменных представлена в таблице 3.

При оценке точности модели были использованы известные формулы для подсчета Weighted Absolute Percent Error (WAPE) и Root Mean Square Error (RMSE). Как видно из таблицы, точность модели достаточно высокая на рассматриваемых данных. Это не гарантирует высокой точности и при дальнейшем прогнозировании, но данное обстоятельство будет компенсировано естественным процессом обновления и уточнения модели.

Таблица 3 – Значение динамической причинно-следственной схемы связей переменных задачи

V_{ar}	WAPE	RMSE	V_{ar}	WAPE	RMSE
X_1	90,1	92,4	X_7	83,7	88,3
X_2	95,5	96,9	X_8	89,4	92,2
X_3	80,8	85,9	X_9	61,5	82,3
X_4	88,7	89,3	X_{10}	81,0	85,2
X_5	78,4	92,1	X_{11}	84,5	90,3
X_6	89,7	92,7			

Параметры модели, полученные в результате оптимизации с использованием алгоритма Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS) функции потерь затем были использованы для построения графиков временных рядов.

Особенность подобранных методом Бroyдена-Флетчера-Гольдфарба-Шанно параметров заключается в том, что значение функции ошибки стабильно для всех графиков ожидаемых экономических показателей. То есть не существует ни одного графика, построенного по этим параметрам, для которого сумма значений функции потерь было бы существенно больше, чем для других графиков.

При этом, что достаточно очевидно, реализация этого метода без ограничения по памяти показала себя несколько лучше, чем реализация с ограничениями. Так как количество параметров рассматриваемой функции сравнительно невелико и составляет 121 (n^2 от количества параметров), то нет причин выбирать более эффективный по памяти, но менее точный алгоритм.

Полученная на предыдущем этапе модель вошла как составная часть в функцию ошибки, что позволило рассматривать параметры, соответствующие экономическим показателям таким как Валовой внутренний продукт, Производительность труда, Экспорт товаров и Промышленное производство как константы.

ЗАКЛЮЧЕНИЕ

При выполнении ВКР были решены следующие задачи:

- произведен поиск, перевод и анализ результатов современных международных научных публикаций, посвященных разработке математических моделей системной динамики, в частности, с использованием нейронных сетей;
- уточнена предметная область и построен вариант модели системной динамики основных экономических показателей государств в связи с развитием водородной энергетики;
- сделан обзор и выбор инструментов решения задачи;
- был введен и использован для развития модели аппарат на основе нейронных сетей;
- произведена разработка, программная реализация и тестирование программного средства.

Таким образом, цель ВКР была успешно достигнута. По результатам работы опубликована статья [12] в международном журнале, индексируемом в Scopus, результаты были доложены на международной конференции [13] «Управление развитием крупномасштабных систем» в Институте проблем управления РАН и на международной научной конференции «Компьютерные науки и информационные технологии» в Саратовском университете.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 *Engelbrecht, A. P.* Computational intelligence: An introduction / A. P. Engelbrecht. — Second edition. — Hoboken, N.J.: John Wiley and Sons, 2007.
- 2 *Mičušík, D.* Application of feed-forward artificial neural networks to the identification of defective analog integrated circuits / D. Mičušík, V. Stopjaková, L. Beňušková // *Neural Computing & Applications*. — 2002. — Vol. 11, no. 1. — Pp. 71–79.
- 3 *Chang, W.-D.* Recurrent neural network modeling combined with bilinear model structure / W.-D. Chang // *Neural Computing & Applications*. — 2014. — Vol. 24, no. 3-4. — Pp. 765–773.
- 4 *Kohonen, T.* The self-organizing map / T. Kohonen // *Proceedings of the IEEE*. — 1990. — Vol. 78, no. 9. — Pp. 1464–1480.
- 5 *Mhaskar, H. N.* Neural networks for function approximation // *Neural networks for signal processing V* / Ed. by F. E. Girosi. — IEEE, 1995. — Pp. 21–29.
- 6 *Kohonen, T.* Statistical pattern recognition with neural networks: benchmarking studies // *Neural networks*. — IEEE, 1993. — Pp. 61–68.
- 7 *Reinhardt, A.* Using neural networks for prediction of the subcellular location of proteins / A. Reinhardt, T. Hubbard // *Nucleic acids research*. — 1998. — Vol. 26, no. 9. — Pp. 2230–2236.
- 8 *Hill, T.* Artificial neural network models for forecasting and decision making / T. Hill, L. Marquez, M. O'Connor, W. Remus // *International Journal of Forecasting*. — 1994. — Vol. 10, no. 1. — Pp. 5–15.
- 9 *Hochreiter, S.* Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural computation*. — 1997. — Vol. 9, no. 8. — Pp. 1735–1780.
- 10 *Mayer, N. M.* Echo state networks and self-prediction / N. M. Mayer, M. Browne // *Biologically Inspired Approaches to Advanced Information Technology* / Ed. by A. J. Ijspeert, M. Murata, N. Wakamiya. — Berlin, Heidelberg: Springer, 2004. — Pp. 40–48.
- 11 *Dupond, S.* A thorough review on the current advance of neural network structures / S. Dupond // *Annual Reviews in Control*. — 2019. — Vol. 14. — Pp. 200–230.

- 12 *Bogomolov, A.* Concerning analysis and control of deviations of economic indicators of countries depending on development of hydrogen power engineering / A. Bogomolov, V. Kushnikov, V. Ivaschenko, I. Tolobaev // *14th International Conference Management of large-scale system development (MLSD)*. — 2021. — Pp. 1–5.
- 13 *Толобаев, И. О.* Модель системной динамики для анализа влияния водородной энергетики на динамику основных экономических показателей / И. О. Толобаев, А. С. Богомоллов // *IX Международная научная конференция «Компьютерные науки и информационные технологии»*. — 2021. — С. 162–165.