УДК 004.852
DOI: 10.53015/18159958_2025_21_2_55

ОПИСАНИЕ КОМПЛЕКСА ПРОГРАММ ИЕРАРХИЧЕСКИХ ДИНАМИЧЕСКИХ НЕЙРО-ОКРЕСТНОСТНЫХ МОДЕЛЕЙ

DESCRIPTION OF THE PROGRAM COMPLEX OF HIERARCHICAL DYNAMIC NEURO-NEIGHBORHOOD MODEL

©2025

Истомин Владимир Александрович, соискатель кафедры автоматизированных систем управления
Istomin Vladimir Aleksandrovich, Applicant of the Department of Automated Control Systems.

Липецкий государственный технический университет, Липецк (Россия)
Lipetsk State Technical University, Lipetsk (Russia)

E-mail: istomin96@mail.ru ORCID: https://orcid.org/0000-0003-3010-1470

Аннотация: В статье представлены иерархические динамические нейро-окрестностные модели (ИДНО), объединяющие нейросетевые методы и окрестностные подходы для моделирования сложных систем. Разработан программный комплекс на Python с поддержкой нейросетей (RBF, TSK, MLP, CNN) и переменных окрестностей, реализована ручная и автоматическая настройка параметров моделей. Эффективность подхода подтверждена экспериментами в различных предметных областях, включая прогнозирование энергопотребления, анализ производственных процессов и оценку стоимости земельных участков.

Ключевые слова: нейронные сети, окрестностные модели, иерархические динамические нейро-окрестностные модели, переменные окрестности, моделирование сложных систем, комплекс программ, Python.

Для цитирования: Истомин, В.А. Описание комплекса программ иерархических динамических нейро-окрестностных моделей / В.А. Истомин // Вести высших учебных заведений Черноземья. – 2025. – Т. 21, № 2 (78). – С. 55-67. – DOI 10.53015/18159958_2025_21_2_55.

Abstract: The article presents hierarchical dynamic neural-neighborhood models (HDNN) that combine neural network methods and neighborhood approaches for modeling complex systems. A software package in Python with support for neural networks (RBF, TSK, MLP, CNN) and neighborhood variables has been developed, manual and automatic tuning of model parameters has been implemented. The effectiveness of the approach has been confirmed by experiments in various subject areas, including energy consumption forecasting, production process analysis, and land valuation.

Keywords: neural networks, neighborhood models, hierarchical dynamic neuro-neighborhood models, neighborhood variables, modeling of complex systems, software package, Python.

For citation: Istomin, V.A. Description of the program complex of hierarchical dynamic neuro-neighborhood model / V.A. Istomin // Vesti of Higher Educational Institutions of the Chernozem region. – 2025. – Vol. 21, № 2 (78). – P. 55-67. – DOI 10.53015/18159958_2025_21_2_55.

ВВЕДЕНИЕ

Развитие современных методов моделирования сложных систем требует интеграции различных подходов, способных учитывать как локальные взаимосвязи между элементами, так и глобальные структурные особенности [1–6]. Одним из перспектив-

ных направлений в данной области являются иерархические динамические нейро-окрестностные модели (ИДНО) [7–10], представляющие собой гибрид нейронных [11–17] и окрестностных моделей [18–21]. Эти модели обладают способностью к адаптации и детализированному представлению структуры системы благодаря использованию вложенных нейронных сетей и переменных окрестностей, отражающих изменчивость связей между элементами.

В рамках настоящего исследования был разработан комплекс программ, реализующий математический аппарат ИДНО. Предложенные модели отличаются многоуровневой иерархией, возможностью настройки динамических связей как по состояниям, так и по выходам модели, а также гибкой архитектурой, включающей различные типы нейросетевых узлов, таких как радиально-базисные сети (RBF), нечеткие сети Такаги-Сугено-Канга (TSK) и другие. Особое внимание уделено алгоритмам идентификации, позволяющим использовать как ручной, так и автоматический подбор параметров, включая структуры с переменными окрестностями.

Разработка комплекса программ направлена на создание универсального инструмента имитационного моделирования и прогнозирования поведения сложных систем с учётом изменений их структуры и функциональных правил. Представленный программный комплекс позволяет не только конструировать модели, но и управлять процессом их обучения и настройки через графический интерфейс.

ПОСТАНОВКА ЗАДАЧИ

Современные распределённые динамические системы, обладающие сложной внутренней структурой и многообразием взаимодействий между элементами, требуют применения новых методов моделирования, способных адекватно отражать как пространственные, так и временные аспекты их функционирования. В качестве эффективного инструмента для описания таких систем предлагается использование ИДНО-моделей, сочетающих в себе преимущества нейросетевых методов и подходов на основе окрестностей.

Целью настоящей работы является разработка и исследование эффективных иерархических динамических нейро-окрестностных моделей для моделирования сложных распределённых систем. В рамках этой цели решаются следующие задачи: реализация программного комплекса, обеспечивающего идентификацию ИДНО-моделей с возможностью выбора архитектуры нейросетевых компонентов, метода подбора параметров и учета переменных окрестностей.

Разрабатываемый программный комплекс предназначен для исследования свойств ИДНО-моделей и проведения вычислительных экспериментов. Он ориентирован на задачи анализа, прогнозирования и структурного проектирования сложных систем, при этом предоставляет пользователю как ручные, так и автоматические механизмы настройки параметров моделей.

Следует отметить, что, несмотря на универсальность предлагаемых решений, реализация моделей требует предварительной подготовки данных и построения структуры модели в соответствии с логикой функционирования исследуемой системы. Это накладывает определённые ограничения на применение комплекса в условиях недостатка информации о внутренней структуре системы.

МЕТОДЫ ИССЛЕДОВАНИЯ

ИДНО-модели представляют собой гибрид окрестностных моделей и нейронных сетей, реализованных в виде иерархической структуры. Узлы второго уровня в модели включают одну или две нейросети, обеспечивающие идентификацию по переходам и выходам системы. Это позволяет гибко учитывать как структурные, так и поведенческие особенности моделируемой системы.

В рамках реализации узлов второго уровня ИДНО-моделей применялись следующие типы нейронных сетей:

– RBF – для задач аппроксимации и прогнозирования в условиях ограниченного объема данных;

– TSK – для работы с логически интерпретируемыми структурами;

– многослойный персептрон (MLP) – как универсальное средство для решения задач регрессии и классификации;

– свёрточные нейронные сети (CNN) – применялись в задачах, связанных с пространственно-временной обработкой изображений, в частности в рамках интеграции моделей с архитектурой You Only Look Once (YOLO) для детекции объектов и событий в видеопотоках и изображениях.

Выбор типа нейросетевой архитектуры осуществлялся на основе специфики задачи, а также характеристик доступных данных и требований к результату моделирования.

Программная реализация комплекса была выполнена с использованием языка программирования Python. Для хранения и предварительной обработки входных и выходных данных применялись таблицы формата Excel (xlsx). Для построения и обучения моделей использовались библиотеки NumPy, Pandas, TensorFlow и Keras.

Разработанный комплекс обеспечивает пользовательский выбор конфигурации модели: ручной или автоматический подбор параметров, использование различных типов нейросетей, включение или отключение механизма переменных окрестностей. В процессе работы модель может быть адаптирована под конкретную задачу без необходимости переработки всей архитектуры. Для оценки эффективности разработанных моделей были проведены вычислительные эксперименты на данных из различных предметных областей:

– прогноз энергопотребления умного дома;

– прогноз температурных процессов охлаждения полосы на стане горячей прокатки;

– прогноз износа прокатных рабочих валков;

– прогноз стоимости сельскохозяйственных земельных участков.

Качество работы моделей оценивалось по следующим метрикам:

– ошибка предсказания (в абсолютных и относительных величинах);

– точность классификации (в задачах распознавания);

– средняя абсолютная процентная ошибка (MAPE).

Разнообразие типов данных, предметных областей и критериев качества позволяет утверждать об универсальности предложенного подхода к моделированию сложных динамических систем.

Рассмотрим более подробно комплекс программ.

КОМПЛЕКС ПРОГРАММ

Структура комплекса программ состоит из нескольких ключевых компонентов, которые можно разделить на три основные категории: файлы исходных данных, результаты работы программ и файлы выходных данных. Более подробное описание каждой категории:

1. Файлы исходных данных:

– Обучение. Данные, используемые для обучения модели или системы.

– Проверка. Данные, используемые для проверки и валидации модели.

– Прогноз. Данные, используемые для выполнения прогнозов или предсказаний.

2. Комплекс программ.

3. Файлы выходных данных (это конечные данные, которые могут включать в себя результаты идентификации, проверки и прогнозирования, готовые для дальнейшего анализа или использования):

– Результаты идентификации. Выходные данные, полученные в процессе идентификации или классификации.

– Результаты проверки. Данные, полученные в результате проверки модели, включая метрики оценки.

– Результаты прогнозирования. Данные, содержащие прогнозы или предсказания, сделанные моделью.

Структура комплекса программ представлена на рис.1.

Эта структура предполагает, что комплекс программ обрабатывает входные данные, выполняет необходимые вычисления и анализ, а затем генерирует выходные данные, которые могут быть использованы для принятия решений или дальнейшей об-

работки. Разработанный комплекс программ (рис. 2) может применяться для моделирования работы сложных производственных процессов и систем, представленных в виде совокупности узлов или подсистем, характеризующихся наличием большого количества связей, в том числе изменяющихся в процессе функционирования, а также в образовательном процессе.

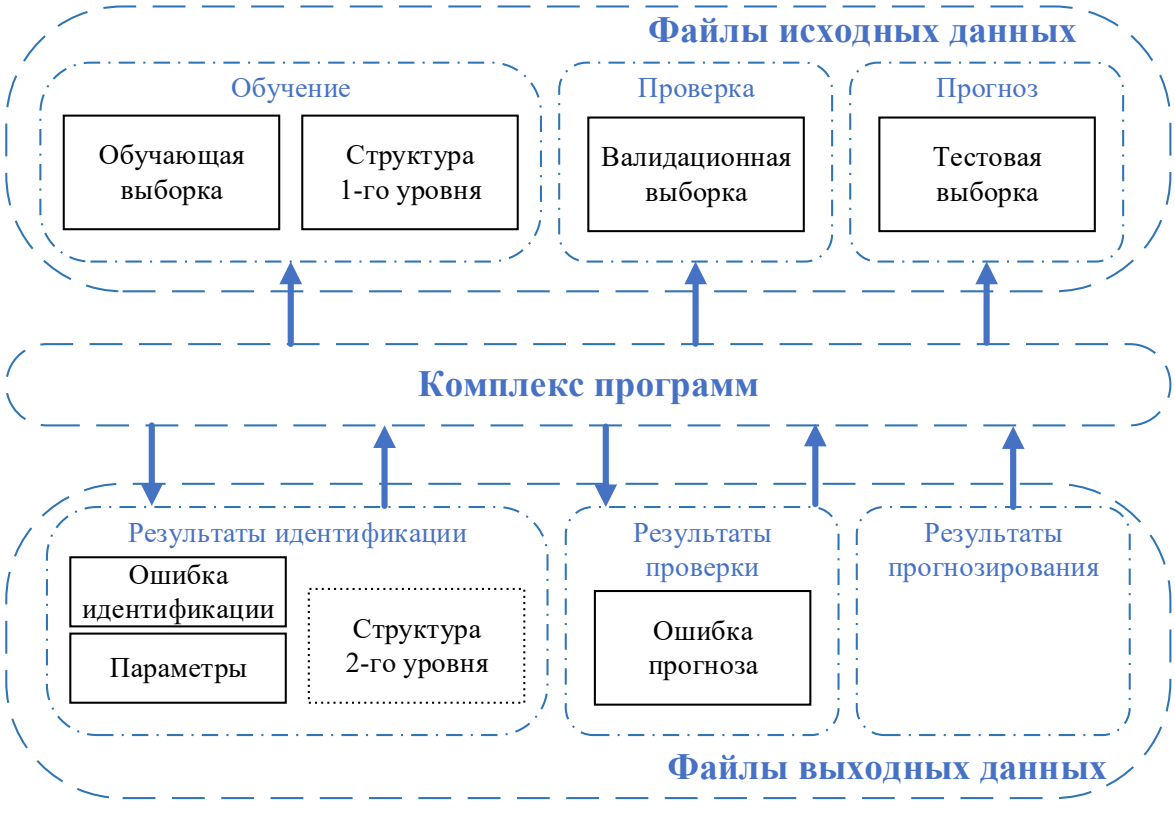


Рис. 1. Структура комплекса программ ИДНО-моделей
Fig. 1. The structure of the software complex for HDNN models

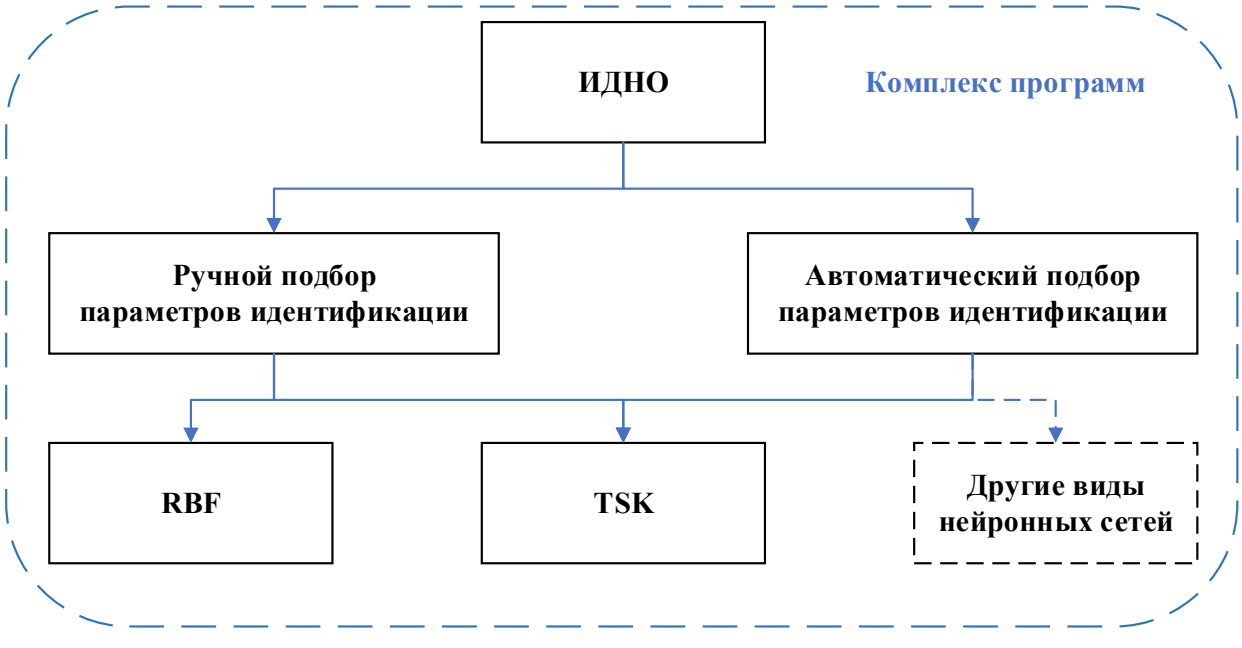


Рис. 2. Комплекс программ ИДНО-моделей
Fig. 2. Software complex for HDNN models

Перейдем к описанию модулей комплекса программ.

МОДУЛЬ 1. ИДЕНТИФИКАЦИЯ ИДНО-МОДЕЛИ

Модуль идентификации ИДНО-модели является ключевым компонентом комплекса программ. Он отвечает за построение и настройку структуры модели, а также за определение её параметров на основе входных данных. Этот модуль обеспечивает начальную подготовку модели для последующего обучения и использования. Алгоритм идентификации ИДНО-модели представлен на рис. 3.

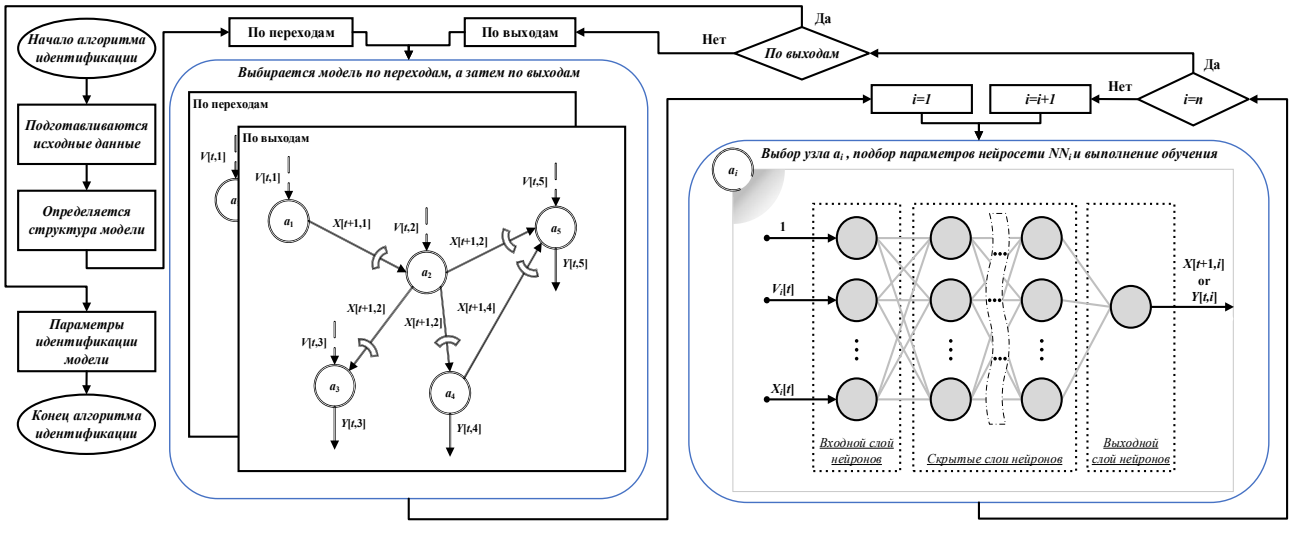


Рис. 3. Идентификация ИДНО-модели
Fig. 3. Identification of the HDNN model

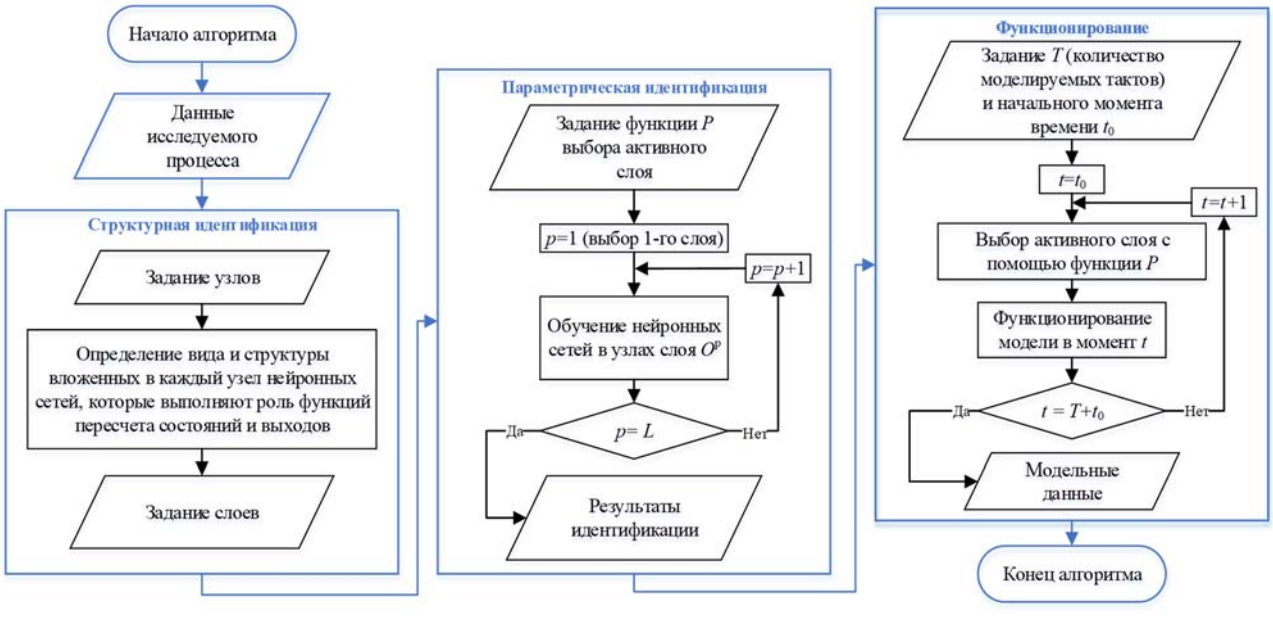


Рис. 4. Идентификация ИДНО-модели с переменными окрестностями
Fig. 4. Identification of HDNN model with variable neighborhoods

МОДУЛЬ 2. ИДЕНТИФИКАЦИЯ ИДНО-МОДЕЛИ С ПЕРЕМЕННЫМИ ОКРЕСТНОСТЯМИ

Модуль идентификации ИДНО-модели с переменными окрестностями расширяет функциональность обычной ИДНО-модели, добавляя возможность динамического изменения связей окрестностей для каждого узла. Это позволяет модели адаптироваться к неоднородным или изменяющимся процессам, что особенно полезно в задачах, где структура системы нестабильна или требует гибкого подхода. Алгоритм идентификации ИДНО-модели с переменными окрестностями представлен на рис. 4.

МОДУЛЬ 3. РУЧНОЙ ПОДБОР ПАРАМЕТРОВ НЕЙРОННОЙ СЕТИ ВНУТРИ УЗЛОВ ИДНО-МОДЕЛИ

Модуль ручного подбора параметров нейронной сети внутри узлов ИДНО-модели предоставляет пользователю возможность самостоятельно настраивать архитектуру и гиперпараметры нейронных сетей, что позволяет учитывать специфику конкретной задачи и данных. Этот модуль особенно полезен в случаях, когда автоматические методы подбора параметров не обеспечивают достаточной точности или, когда требуется точный контроль над моделью.

МОДУЛЬ 4. АВТОМАТИЧЕСКИЙ ПОДБОР ПАРАМЕТРОВ НЕЙРОННОЙ СЕТИ ВНУТРИ УЗЛОВ ИДНО-МОДЕЛИ

Модуль автоматического подбора параметров нейронной сети внутри узлов ИДНО-модели предназначен для оптимизации архитектуры и гиперпараметров нейронных сетей без необходимости ручного вмешательства. Этот модуль использует алгоритмы оптимизации для поиска наилучших параметров, что позволяет значительно сократить время настройки модели и повысить её точность. Алгоритм автоматического подбора параметров ИДНО-модели представлен на рис. 5.

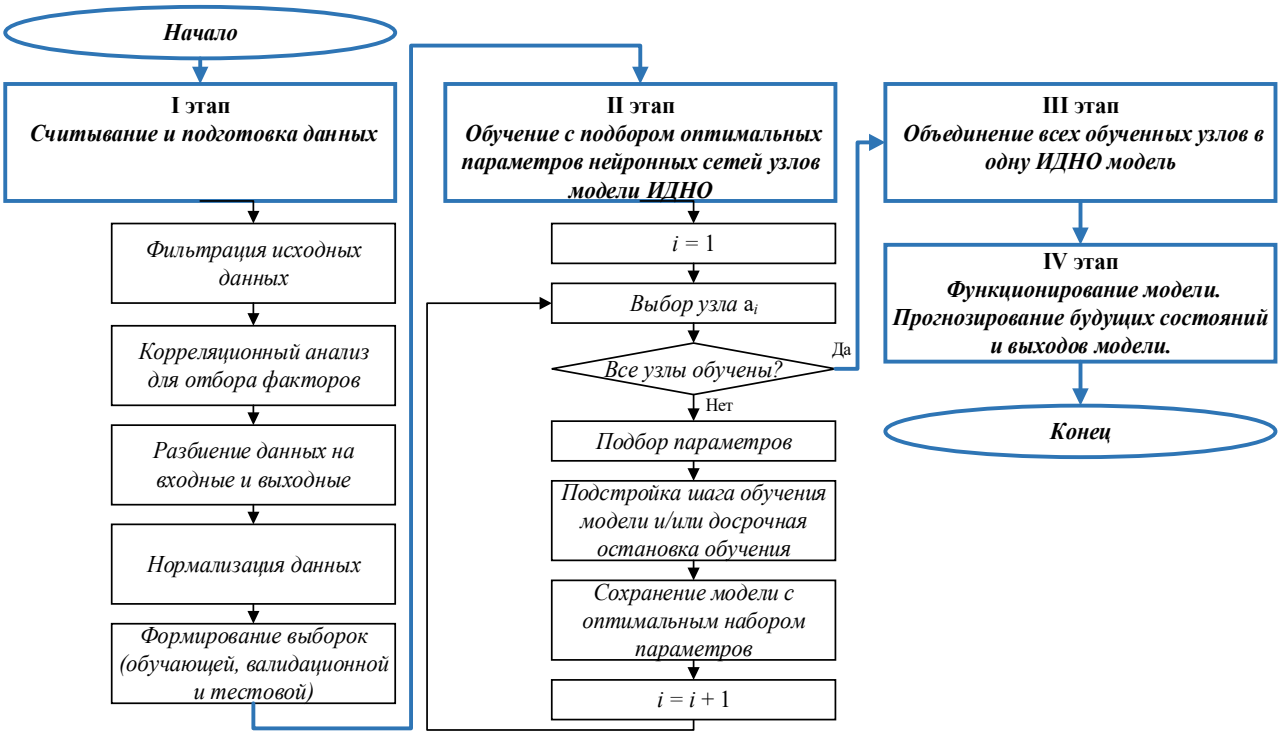
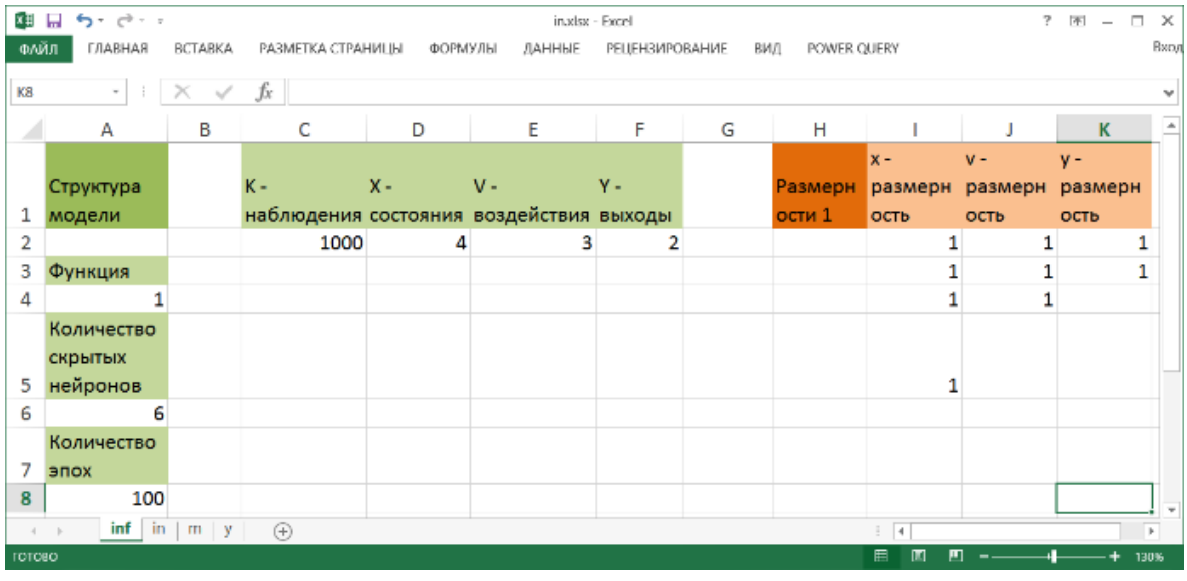
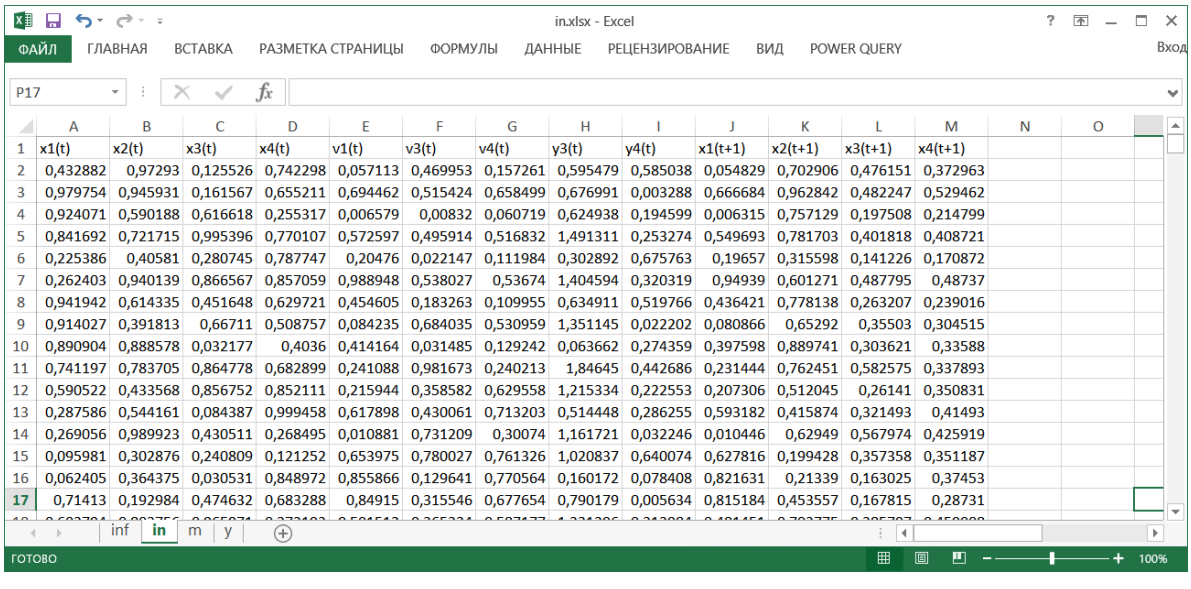


Рис. 5. Алгоритм автоматического подбора параметров ИДНО-модели
Fig. 5. Algorithm of automatic selection of HDNN model parameters



	A	B	C	D	E	F	G	H	I	J	K
1	Структура модели		K - наблюдения	X - состояния	V - воздействия	Y - выходы		Размерности 1	x - размерность	v - размерность	y - размерность
2			1000	4	3	2			1	1	1
3	Функция								1	1	1
4	1								1	1	
5	Количество скрытых нейронов								1		
6	6										
7	Количество эпох										
8	100										

Рис. 6. Пример листа «inf» файла «in.xlsx»
Fig. 6. Example of «inf» sheet of «in.xlsx» file



	A	B	C	D	E	F	G	H	I	J	K	L	M
1	x1(t)	x2(t)	x3(t)	x4(t)	v1(t)	v3(t)	v4(t)	y3(t)	y4(t)	x1(t+1)	x2(t+1)	x3(t+1)	x4(t+1)
2	0,432882	0,97293	0,125526	0,742298	0,057113	0,469953	0,157261	0,595479	0,585038	0,054829	0,702906	0,476151	0,372963
3	0,979754	0,945931	0,161567	0,655211	0,694462	0,515424	0,658499	0,676991	0,003288	0,666684	0,962842	0,482247	0,529462
4	0,924071	0,590188	0,616618	0,255317	0,006579	0,00832	0,060719	0,624938	0,194599	0,006315	0,757129	0,197508	0,214799
5	0,841692	0,721715	0,995396	0,770107	0,572597	0,495914	0,516832	1,491311	0,253274	0,549693	0,781703	0,401818	0,408721
6	0,225386	0,40581	0,280745	0,787747	0,20476	0,022147	0,111984	0,302892	0,675763	0,19657	0,315598	0,141226	0,170872
7	0,262403	0,940139	0,866567	0,857059	0,988948	0,538027	0,53674	1,404594	0,320319	0,94939	0,601271	0,487795	0,48737
8	0,941942	0,614335	0,451648	0,629721	0,454605	0,183263	0,109955	0,634911	0,519766	0,436421	0,778138	0,263207	0,239016
9	0,914027	0,391813	0,66711	0,508757	0,084235	0,684035	0,530959	1,351145	0,022202	0,080866	0,65292	0,35503	0,304515
10	0,890904	0,888578	0,032177	0,4036	0,414164	0,031485	0,129242	0,063662	0,274359	0,397598	0,889741	0,303621	0,33588
11	0,741197	0,783705	0,864778	0,682899	0,241088	0,981673	0,240213	1,84645	0,442686	0,231444	0,762451	0,582575	0,337893
12	0,590522	0,433568	0,856752	0,852111	0,215944	0,358582	0,629558	1,215334	0,222553	0,207306	0,512045	0,26141	0,350831
13	0,287586	0,544161	0,084387	0,999458	0,617898	0,430061	0,713203	0,514448	0,286255	0,593182	0,415874	0,321493	0,41493
14	0,269056	0,989923	0,430511	0,268495	0,010881	0,731209	0,30074	1,161721	0,032246	0,010446	0,62949	0,567974	0,425919
15	0,095981	0,302876	0,240809	0,121252	0,653975	0,780027	0,761326	1,020837	0,640074	0,627816	0,199428	0,357358	0,351187
16	0,062405	0,364375	0,030531	0,848972	0,855866	0,129641	0,770564	0,160172	0,078408	0,821631	0,21339	0,163025	0,37453
17	0,71413	0,192984	0,474632	0,683288	0,84915	0,315546	0,677654	0,790179	0,005634	0,815184	0,453557	0,167815	0,28731

Рис. 7. Пример листа «in» файла «in.xlsx»
Fig. 7. Example of sheet «in» of file «in.xlsx»

МОДУЛЬ 5. ИНТЕРФЕЙС КОМПЛЕКСА ПРОГРАММ ИДНО-МОДЕЛИ

Интерфейс комплекса программ ИДНО-модели обеспечивает удобное взаимодействие пользователя со всеми модулями системы. Он предоставляет единую точку доступа для настройки, управления и анализа работы ИДНО-моделей, включая обычную ИДНО-модель, модель с переменными окрестностями, а также инструменты для ручного и автоматического подбора параметров.

Рассмотрим пример входных данных при условии, что у нас ИДНО-модель без переменных окрестностей.

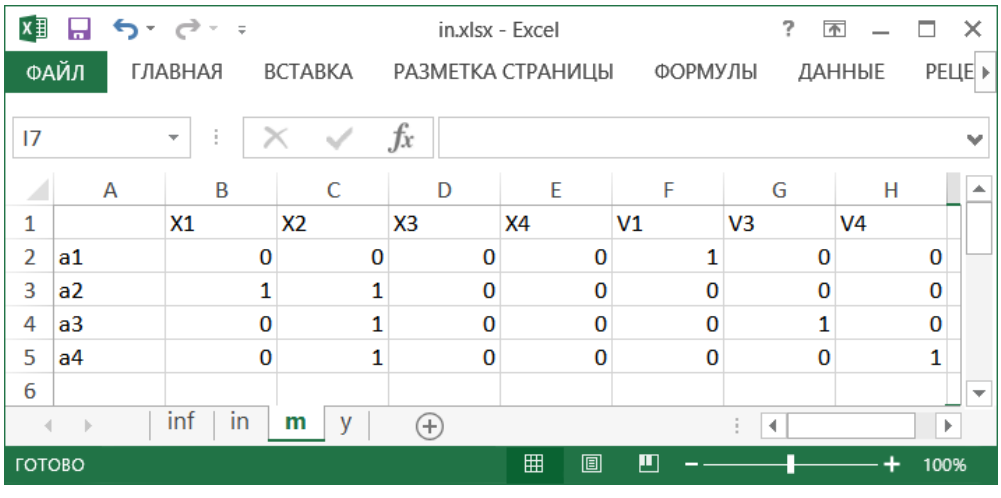
Реализовано считывание и запись данных в Excel с расширением xlsx. Для считывания подготовлен файл «in.xlsx», который включает в себя несколько листов.

Лист «inf» – содержит информацию о структуре иерархической динамической нейро-окрестностной модели, а именно: ко-

личество наблюдений, состояний, воздействий, выходов и соответствующие им размерности. Также в этом листе указывается функция активации, количество нейронов на скрытом слое и эпох обучения нейронной сети (рис. 6).

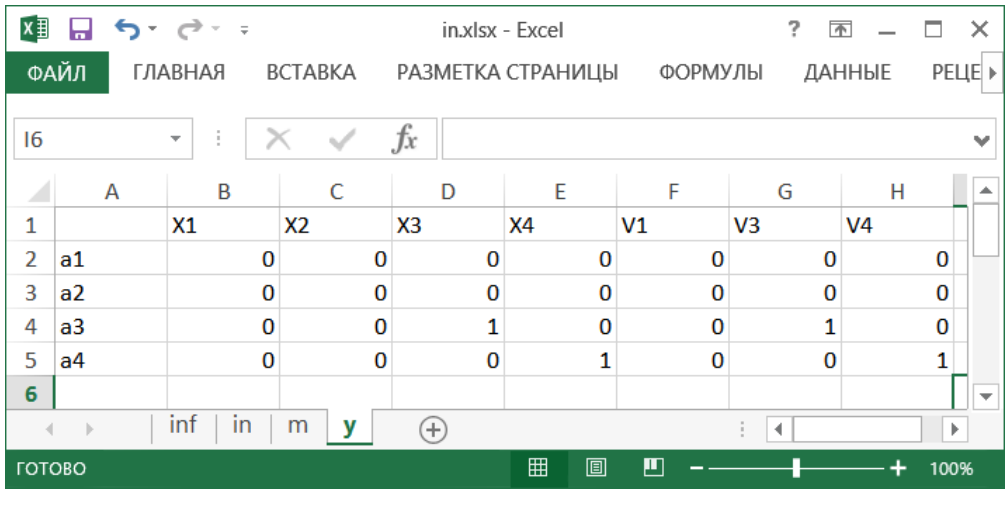
Лист «in» – на этом листе находятся непосредственно все наблюдения модели по входам, состояниям и выходам модели на настоящий момент и состояния в следующий момент времени, что необходимо для выполнения идентификации модели (рис. 7).

Лист «m» – этот лист хранит матрицу связей узлов по состояниям модели, в ней отражены воздействия на каждый узел, которые влияют на пересчет следующего состояния данного узла (рис. 8).



	A	B	C	D	E	F	G	H
1		X1	X2	X3	X4	V1	V3	V4
2	a1	0	0	0	0	1	0	0
3	a2	1	1	0	0	0	0	0
4	a3	0	1	0	0	0	1	0
5	a4	0	1	0	0	0	0	1
6								

Рис. 8. Пример листа «m» файла «in.xlsx»
Fig. 8. Example of sheet «m» of file «in.xlsx»



	A	B	C	D	E	F	G	H
1		X1	X2	X3	X4	V1	V3	V4
2	a1	0	0	0	0	0	0	0
3	a2	0	0	0	0	0	0	0
4	a3	0	0	1	0	0	1	0
5	a4	0	0	0	1	0	0	1
6								

Рис. 9. Пример листа «y» файла «in.xlsx»
Fig. 9. Example of sheet «y» of file «in.xlsx»

Лист «y» – этот лист хранит матрицу связей узлов по выходам модели, в ней отражены воздействия на каждый узел, которые влияют на пересчет выхода данного узла (рис. 9).

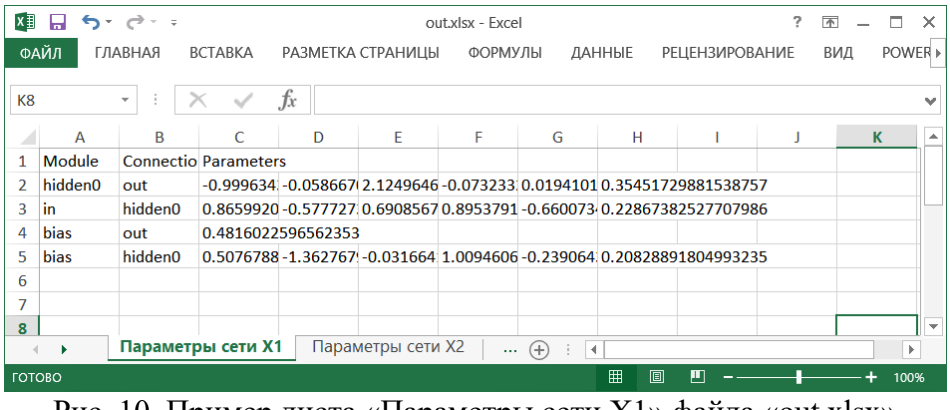
Запись результатов программы выполняется в файл «out.xlsx». В этот файл записывается такая информация, как параметры каждой из обученных сетей для каждого состояния и выхода, рассчитанные ошибки обучения сетей и предсказанные значения всех сетей. Файл «out.xlsx» включает листы, перечисленные ниже.

Лист «Параметры сети 1 #№» содержит информацию по параметрам сети, где # – это состояние или выход модели, № – это

номер состояния или выхода модели. Первый столбец «Module» обозначает слой, из которого происходит связь со слоем «Connection to», и такая связь имеет следующие параметры, которые записываются в строчку, начиная от столбца «Parameters» (рис. 10).

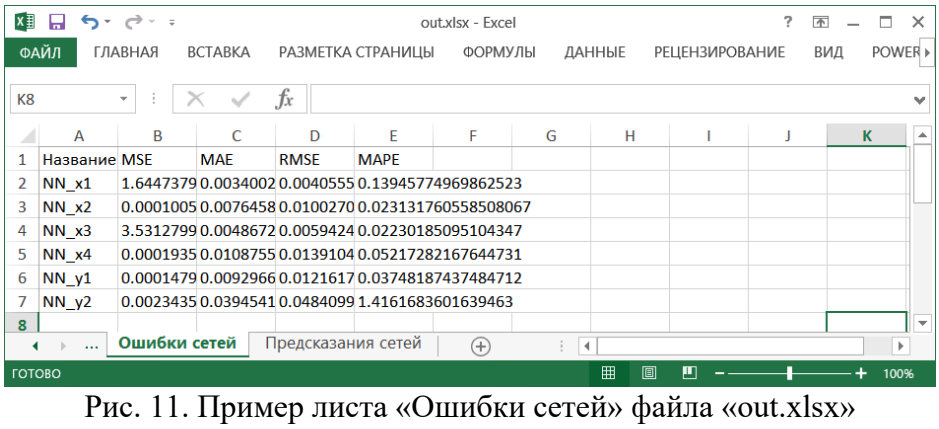
Лист «Ошибки сетей» – это лист, на котором представлены ошибки идентификации иерархической динамической нейро-окрестностной модели (рис. 11), где в первом столбце содержится «Название сети», которое отражает сеть пересчета конкретного состояния или выхода модели и соответствующие им ошибки. Лист «Предсказания сетей» – лист, который содержит пересчитанные модельные данные для каждого наблюдения после идентификации (рис. 12).

Если используется ИДНО-модель с переменными окрестностями, то количество листов «in#», «m#» и «y#» будет равняться количеству слоёв, где # – это номер соответствующего слоя. Интерфейс программы представлен на рис. 13 и 14.



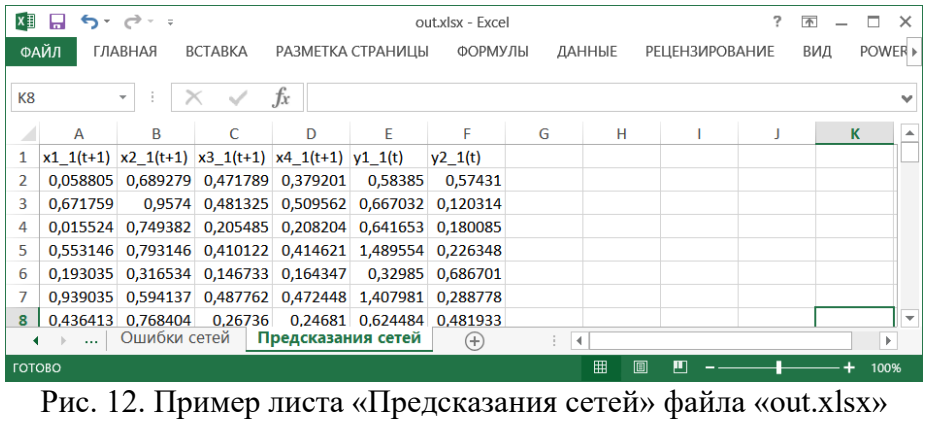
	A	B	C	D	E	F	G	H	I	J	K
1	Module	Connectio	Parameters								
2	hidden0	out	-0.999634	-0.058667	2.1249646	-0.073233	0.0194101	0.35451729881538757			
3	in	hidden0	0.8659920	-0.577727	0.6908567	0.8953791	-0.660073	0.22867382527707986			
4	bias	out	0.4816022596562353								
5	bias	hidden0	0.5076788	-1.362767	-0.031664	1.0094606	-0.239064	0.20828891804993235			
6											
7											
8											

Рис. 10. Пример листа «Параметры сети X1» файла «out.xlsx»
Fig. 10. Example of sheet « Network parameters X1» of file «out.xlsx»



	A	B	C	D	E	F	G	H	I	J	K
1	Название	MSE	MAE	RMSE	MAPE						
2	NN_x1	1.6447379	0.0034002	0.0040555	0.13945774969862523						
3	NN_x2	0.0001005	0.0076458	0.0100270	0.023131760558508067						
4	NN_x3	3.5312799	0.0048672	0.0059424	0.02230185095104347						
5	NN_x4	0.0001935	0.0108755	0.0139104	0.05217282167644731						
6	NN_y1	0.0001479	0.0092966	0.0121617	0.03748187437484712						
7	NN_y2	0.0023435	0.0394541	0.0484099	1.4161683601639463						
8											

Рис. 11. Пример листа «Ошибки сетей» файла «out.xlsx»
Fig. 11. Example of sheet « Network errors » of file «out.xlsx»



	A	B	C	D	E	F	G	H	I	J	K
1	x1_1(t+1)	x2_1(t+1)	x3_1(t+1)	x4_1(t+1)	y1_1(t)	y2_1(t)					
2	0,058805	0,689279	0,471789	0,379201	0,58385	0,57431					
3	0,671759	0,9574	0,481325	0,509562	0,667032	0,120314					
4	0,015524	0,749382	0,205485	0,208204	0,641653	0,180085					
5	0,553146	0,793146	0,410122	0,414621	1,489554	0,226348					
6	0,193035	0,316534	0,146733	0,164347	0,32985	0,686701					
7	0,939035	0,594137	0,487762	0,472448	1,407981	0,288778					
8	0,436413	0,768404	0,26736	0,24681	0,624484	0,481933					

Рис. 12. Пример листа «Предсказания сетей» файла «out.xlsx»
Fig. 12. Example of the “Network Predictions” sheet of the file “out.xlsx”

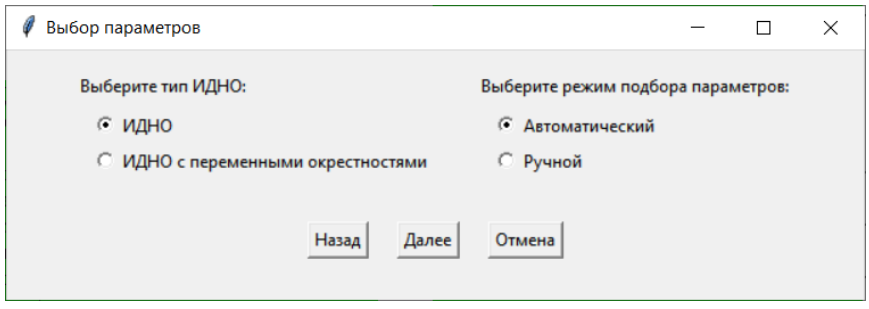


Рис. 13. Окно запуска программы
Fig. 13. Program launch window

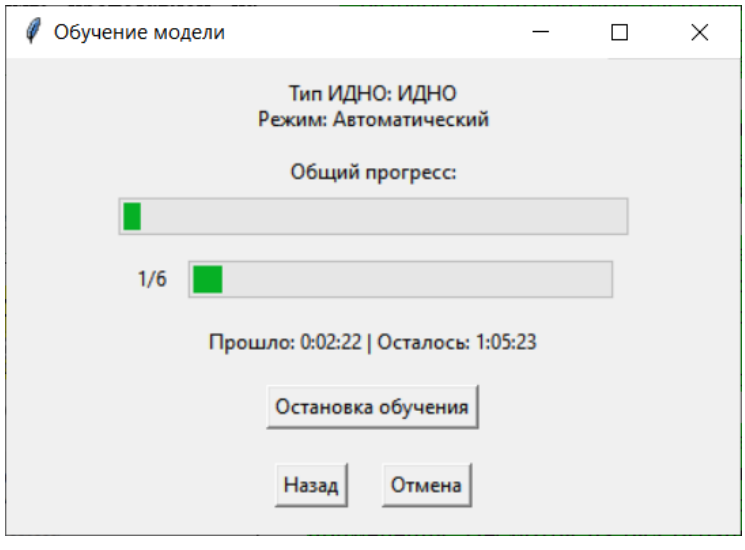


Рис. 14. Окно процесса обучения ИДНО-модели
Fig. 14. HDNN model training process window

Таким образом, приведено описание модулей комплекса программ идентификации иерархических динамических нейро-окрестностных моделей.

ЗАКЛЮЧЕНИЕ

В статье представлен комплекс программ для реализации иерархических динамических нейро-окрестностных моделей (ИДНО), сочетающих преимущества нейросетевых методов и окрестностных подходов. Разработанный инструментарий позволяет эффективно решать задачи моделирования сложных систем с изменяющейся структурой и динамическими связями.

Основные научные результаты исследования включают:

1. Разработку модульной архитектуры, поддерживающей:
- различные типы нейронных сетей (RBF, TSK, MLP, CNN);
- механизм переменных окрестностей;
- гибридный подход к настройке параметров (ручной и автоматический).

2. Экспериментальное подтверждение эффективности метода на задачах:
- прогнозирования энергопотребления;
- анализа производственных процессов;
- оценки стоимости земельных участков.

Разработанный подход обеспечивает гибкость в структурировании моделей, высокую точность предсказаний и универсальность применения. Несмотря на ряд ограничений, связанных с необходимостью тщательной подготовки входных данных и структурной конфигурации модели, предложенный комплекс может быть успешно использован как инструмент моделирования, анализа и поддержки принятия решений в различных предметных областях.

СПИСОК ЛИТЕРАТУРЫ

1. Яглом И.М. Математические структуры и математическое моделирование. Москва : Ленанд, 2018. 144 с. ISBN 978-5-9710-5281-4.
2. Горлач Б.А., Шахов В.Г. Математическое моделирование. Построение моделей и численная реализация : учебное пособие. 5-е изд. Санкт-Петербург : Лань, 2023. 272 с. ISBN 978-5-507-46275-9.
3. Моделирование систем и процессов : учебник для вузов / под ред. В.Н. Волковой, В.Н. Козлова. 2-е изд., перераб. и доп. Москва : Юрайт, 2025. 510 с. (Высшее образование). ISBN 978-5-534-18563-8.
4. Exploring Mathematical Modeling with Young Learners / ed. by J.M. Suh, L.D. English, M.H. Wickstrom. Cham, Switzerland : Springer International Publishing, 2021. 453 p.
5. Власов М.В. Имитационное моделирование : учебно-методическое пособие для подготовки к лекционным и практическим занятиям. Новочеркасск : ЮРГПУ (НПИ), 2016. 60 с.
6. Колесов Ю.Б., Сениченков Ю.Б. Математическое моделирование сложных динамических систем. Санкт-Петербург : Политех-Пресс, 2019. 242 с. ISBN 978-5-7422-6685-3.
7. Свидетельство о государственной регистрации программы для ЭВМ № 2021666960 Российская Федерация. Идентификация иерархических динамических нейро-окрестностных моделей : № 2021666078 : заявл. 13.10.2021 : опубл. 22.10.2021 / И.А. Седых, В.А. Истомин ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Липецкий государственный технический университет».
8. Свидетельство о государственной регистрации программы для ЭВМ № 2024660588 Российская Федерация. Автоматический подбор оптимальных параметров для идентификации иерархических динамических нейро-окрестностных моделей : № 2024618351 : заявл. 18.04.2024 : опубл. 08.05.2024 / И.А. Седых, В.А. Истомин ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Липецкий государственный технический университет».
9. Седых И.А., Истомин В.А. Применение иерархических динамических нейро-окрестностных моделей // XIV Всероссийское совещание по проблемам управления : сборник научных трудов, Москва, 17-20 июня 2024 г. Москва, 2024. С. 3000-3004.
10. Седых И.А., Истомин В.А. Нейро-окрестностные модели как новый класс иерархических динамических окрестностных моделей. DOI 10.15593/2499-9873/2024.2.03 // Прикладная математика и вопросы управления. 2024. № 2. С. 34-48.
11. Цехановский В.В., Жукова Н.А., Бутырский Е.Ю. Искусственные нейронные сети : учебник. Москва : Кнорус, 2023. 352 с. ISBN 978-5-406-10678-5.
12. Николенко С.И., Кадурин А.А., Архангельская Е.О. Глубокое обучение. Погружение в мир нейронных сетей. Санкт-Петербург : Питер, 2018. 480 с. ISBN 978-5-496-02536-2.
13. Chollet F. Deep Learning with Python. 2nd ed. Shelter Island, NY : Manning Publications, 2021. 384 p. ISBN 978-1-61729-443-3.
14. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. 2-е изд. Санкт-Петербург : Диалектика, 2020. 1040 с. : ил. ISBN 978-5-907203-33-4.
15. Constructing Neural Network Based Models for Simulating Dynamical Systems / C. Legaard, T. Schranz, G. Schweiger [et al.]. DOI 10.1145/3567591 // ACM Computing Surveys. 2023. Vol. 55 (11), № 236. P. 1-34.
16. Галушкин А.И. Нейронные сети. Основы теории. Москва : Горячая Линия–Телеком, 2017. 496 с. ISBN 978-5-9912-0082-0.
17. Аникин М.В., Никифоров М.Б., Таганов А.И. Нейросетевые системы искусственного интеллекта в задачах обработки изображений. Москва : Горячая линия–Телеком, 2017. 152 с. ISBN 978-5-9912-0537-5.
18. Scaled cluster consensus of discrete-time multi-agent systems with general directed topologies / B. Hou, F. Sun, H. Li [at al.] // International Journal of Control. 2016. Vol. 89, № 47. P. 3839-3845.

19. Макаров К.Н., Седых И.А. Идентификация комплекснозначных окрестностных моделей с нечеткой кластеризацией данных // Математика и математическое моделирование : сборник материалов XVIII Всероссийской молодёжной научно-инновационной школы, Саров, 10-12 апр. 2024 г. Саров, 2024. С. 484.

20. Shang Y. Consensus in averager-copier-voter networks of moving dynamical agents. Text: electronic // Chaos. 2017. Vol. 27 (2). P. 023116.

21. Седых И.А., Макаров К.Н. Сравнение методов нечеткой кластеризации данных при идентификации комплекснозначной динамической окрестностной модели // Управление большими системами : труды XX Всероссийской школы-конференции молодых ученых, Новочеркасск, 10-13 сент. 2024 г. Новочеркасск, 2024. С. 47-54.

REFERENCES

1. Yaglom I.M. Mathematical Structures and Mathematical Modeling. Moscow : Lenand. 2018. 144 p. ISBN 978-5-9710-5281-4.

2. Gorlach B.A., Shakhov V.G. Mathematical Modeling. Model Construction and Numerical Implementation : textbook. 5th ed. Saint Petersburg : Lan, 2023. 272 p. ISBN 978-5-507-46275-9.

3. Modelirovanie sistem i protsessov Modeling of Systems and Processes : textbook for Universities / ed. by V.N. Volkova, V.N. Kozlov. 2nd ed., revised and enlarged. Moscow : Yurait, 2025. 510 p. (Higher Education). ISBN 978-5-534-18563-8.

4. Exploring Mathematical Modeling with Young Learners / ed. by J.M. Suh, L.D. English, M.H. Wickstrom. Cham, Switzerland : Springer International Publishing, 2021. 453 p.

5. Vlasov M.V. Simulation Modeling : teaching aid for lectures and practical classes. Novocherkassk : YRSPU (NPI), 2016. 60 p.

6. Kolesov Yu.B., Senichenkov Yu.B. Mathematical Modeling of Complex Dynamic Systems. Saint Petersburg : Politekh-Press, 2019. 242 p. ISBN 978-5-7422-6685-3.

7. Certificate of State Registration of Computer Program № 2021666960 Russian Federation. Identification of Hierarchical Dynamic Neuro-Neighborhood Models : Application № 2021666078 : filed 13.10.2021 : published 22.10.2021 / I.A. Sedykh, V.A. Istomin ; applicant Lipetsk State Technical University.

8. Certificate of State Registration of Computer Program № 2024660588 Russian Federation. Automatic Selection of Optimal Parameters for Identification of Hierarchical Dynamic Neuro-Neighborhood Models : Application № 2024618351 : filed 18.04.2024 : published 08.05.2024 / I.A. Sedykh, V.A. Istomin ; applicant Lipetsk State Technical University.

9. Sedykh I.A., Istomin V.A. Application of hierarchical dynamic neuro-neighborhood models // XIV All-Russian Conference on Control Problems : Proceedings, Moscow, June 17-20, 2024. Moscow, 2024. P. 3000-3004.

10. Sedykh I.A., Istomin V.A. Neuro-neighborhood models as a new class of hierarchical dynamic neighborhood models. DOI 10.15593/2499-9873/2024.2.03 // Applied Mathematics and Control Problems. 2024. № 2. P. 34-48.

11. Tsekhanovsky V.V., Zhukova N.A., Butyrsky E.Yu. Artificial Neural Networks : textbook. Moscow : Knorus, 2023. 352 p. ISBN 978-5-406-10678-5.

12. Nikolenko S.I., Kadurin A.A., Arkhangelskaya E.O. Deep Learning. Immersion in the World of Neural Networks. Saint Petersburg : Piter, 2018. 480 p. ISBN 978-5-496-02536-2.

13. Chollet F. Deep Learning with Python. 2nd ed. Shelter Island, NY : Manning Publications, 2021. 384 p. ISBN 978-1-61729-443-3.

14. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. 2nd ed. Saint Petersburg : Dialektika, 2020. 1040 p. ISBN 978-5-907203-33-4.

15. Constructing Neural Network Based Models for Simulating Dynamical Systems / C. Legaard, T. Schranz, G. Schweiger [et al.]. DOI 10.1145/3567591 // ACM Computing Surveys. 2023. Vol. 55 (11), № 236. P. 1-34.

16. Galushkin A.I. Neural Networks. Fundamentals of Theory. Moscow : Goryachaya Liniya–Telekom, 2017. 496 p. ISBN 978-5-9912-0082-0.

17. Anikin M.V., Nikiforov M.B., Taganov A.I. Neural Network Artificial Intelligence Sys-

tems in Image Processing Tasks. Moscow : Goryachaya liniya–Telekom, 2017. 152 p. ISBN 978-5-9912-0537-5.

18. Scaled cluster consensus of discrete-time multi-agent systems with general directed topologies / B. Hou, F. Sun, H. Li [at al.] // International Journal of Control. 2016. Vol. 89, № 47. P. 3839-3845.

19. Makarov K.N., Sedykh I.A. Identification of Complex-Valued Neighborhood Models with Fuzzy Data Clustering // Mathematics and Mathematical Modeling : Proc. of the XVIII All-Russian Youth Scientific and Innovative School, Sarov, April 10-12, 2024. Sarov. 2024. P. 484.

20. Shang Y. Consensus in averager-copier-voter networks of moving dynamical agents. Text: electronic // Chaos. 2017. Vol. 27 (2). P. 023116.

21. Sedykh I.A., Makarov K.N. Comparison of Data Clustering Fuzzy Methods for Identification of Complex-Valued Dynamic Neighborhood Models // Large Systems Control : Proc. of the XX All-Russian Young Scientists School-Conference, Novocherkassk, September 10-13, 2024. Novocherkassk, 2024. P. 47-54.