

УДК 004.8.032.26; 681.3

*С.П. Алёшин*

Полтавский национальный технический университет им. Ю. Кондратюка,  
г. Полтава, Украина  
aleshsp@ukr.net

## Нейросетевые модели принятия решений быстрого реагирования для критических инфраструктур

Работа посвящена проблеме автоматизации принятия решений в режиме реального времени для сложных социотехнических объектов в базе эмуляторов нейросреды. Предложена технология моделирования базовых процессов автоматизации принятия решений (распознавание состояний, выделение однородных данных, прогнозирование динамики поведения) для критических инфраструктур в разных предметных областях. В основе подхода лежит идея создания дополнительного, независимого инструмента принятия решения в режиме реального времени. Приведены модели и алгоритмы, реализованные в среде стандартных нейроэмуляторов формата Statistika Neural Network, обеспечивающие состоятельные показатели надежности принимаемых решений.

### Введение

Критическая инфраструктура подразумевает совокупность физических или виртуальных систем и средств, важных для государства (гражданина) в такой мере, что их выход из строя или уничтожение могут привести к губительным последствиям в области экономики, здравоохранения и безопасности нации (личности). Это касается объектов разных областей деятельности: здравоохранения, кредитно-финансового, банковского и научно-исследовательского секторов, промышленности, энергетики, нефтегазового комплекса, обеспечения продовольствием, транспорта, коммунального хозяйства, включая водоснабжение, связи, гражданской обороны и др.

Эффективность мониторинга, макродиагностики и оперативной коррекции динамики функционирования критических инфраструктур с целью обеспечения безопасности были и остаются актуальной проблемой [1], [2]. С учетом структуры подобных объектов и характера внутренних взаимосвязей такие объекты относятся к классу сложных социотехнических систем (ССТС) [2], [3], характерные черты которых:

– трудности формализованного математического описания процессов функционирования, а следовательно, и невозможность использования традиционных проектных процедур и операций автоматизации, основанных на применении методов оптимального проектирования;

– случайный характер изменения среды функционирования указанных объектов, в которой возможны как прогнозируемые изменения параметров, так и форс-мажорные события;

– практическая невозможность или экономическая нецелесообразность непрерывного измерения технологических параметров объектов и возмущающих воздействий со стороны среды функционирования.

В работе [3] предложен подход к выделению и описанию класса сложных социотехнических систем путем расчета метрики адекватности модели на основе статистических критериев близости с учетом особенностей предметной области. Приведено количественное обоснование границы класса ССТС как отображение пространства факторов на пространство состояний в допустимых границах адекватности на основе соотношения

$$F : X \rightarrow Y, X \subset \mathfrak{R}^m, Y \subset \mathfrak{R}^k, \quad (1)$$

при условии, что

$$R(M, O) \geq \delta \geq 0, \quad (2)$$

$X$  – множество выборок признаков описания объекта,  $Y$  – множество состояний объекта.  $X^m = \{x_1, x_2, \dots, x_m\} \subset X$  – конечный массив обучающих выборок.  $F$  – функционал преобразования пространства наблюдений (признаков) в пространство состояний (принятых решений);  $k$  и  $m$  – соответственно размерность состояний (объем алфавита классов) и размерность факторов (объем словаря признаков);  $R(M, O)$  – расстояние между объектом и его моделью в некотором метрическом пространстве с заданной метрикой  $r(a, b)$ , а  $\delta$  – допустимый предел неадекватности в заданном метрическом пространстве.

Если критерий (2) соответствует исследуемому объекту, то его системообразующие процессы трудно формализуемы и, как правило, не поддаются аналитическому представлению, что препятствует оперативному выявлению и формализации основных факторов, связей между ними и силы влияния на целевую функцию. Ситуация осложняется тем, что критические инфраструктуры в силу особенностей контролируемой предметной области должны реагировать в режиме реального времени. Поэтому искомым базис принятия решений должен быть ориентирован на быстрое реагирование. Классические методы описания динамики подобного объекта системой дифференциальных уравнений и поиска её решения путем сходимости итерационных процедур в многомерном пространстве входного вектора признаков оказываются неэффективны [1], [2]. С одной стороны, итерационный процесс требует определенных временных затрат, с другой – требует применения некоторой технологии преодоления проблемы локальных экстремумов при спуске к решению (глобальному экстремуму). Задача реагирования на быстро меняющуюся ситуацию сводится к реализации базовых процедур ситуационного центра быстрого реагирования (СЦБР) [4]. В них экспертное мнение при принятии решения, не может быть доминирующим, в отличие от классических ситуационных центров [5]. В СЦБР, по определению, первостепенную роль должны играть информационно-технические средства. В силу жестких временных ограничений на принятие решения, а также из-за высокой динамики данных об объекте и среде, в которой он функционирует, построение точной модели поведения такого объекта и обеспечение эффективного управления им остается сегодня актуальной проблемой.

**Целью данной работы** является построение нейросетевых моделей базовых функций для принятия решений в интересах анализа состояния критических инфраструктур. При этом модели должны работать в режиме реального времени и с приемлемой для практики надежностью. В качестве инструмента моделирования выбран пакет нейроммуляторов среды StatSoft в формате модуля Statistika Neural Network.

## Подход к разрешению проблемы

В отмеченных объектах управления, как правило, имеется значительный массив априорных и текущих данных, что является объективной основой для продуктивного применения интеллектуальных технологий для трансформации базы данных в базу знаний. Тогда аналитический подход, основанный на прецедентах, что содержат информацию о закономерностях факторов и состояний, их взаимном влиянии, силе и направлении воздействия для принятия решений становится исключительно важным. Для практического применения такого подхода необходимо найти инструментарий реализации базовых функций процессов автоматического управления объектом, к которым относятся:

- описание и представление объекта или его состояния как образа из некоторого алфавита классов на языке словаря информативных признаков;
- присвоение формальных имен, сопоставление образа объекта конкретного класса с набором соответствующих значений признаков в форме принадлежности к некоторым градациям определенных смысловых шкал;
- формирование обобщенных образов состояний объектов на основе одновременного использования процедур восприятия и идентификации в пространстве априорных данных, которые используются в качестве примеров (массив числовых значений выборки пар «вход-выход»);
- оценка дифференцирующей силы признаков и расстановка их в мажоритарный ряд;
- понижение размерности пространства признаков с сохранением состоятельной для принятия решений информации;
- кластеризация признаков: определение сходств и различий признаков по их смыслу; объединение сходных по смыслу признаков в группы;
- кластеризация обобщенных образов: определение сходств и различий обобщенных образов друг с другом;
- объединение сходных образов в множества со сходными признаками;
- распознавание объектов: сравнение предметного образа конкретного объекта со всеми обобщенными образами и принятие решения о принадлежности к классу;
- выбор оптимальных управляющих факторов: формирование массива возможных управляющих воздействий, анализ их силы и направления, адаптация к предметной области, обеспечение заданных целевых состояний объекта.

Таким образом, разрешение проблемы оперативного (быстрого) реагирования при принятии решений для функциональной безопасности критических инфраструктур сводится к реализации указанных функций путем создания алгоритмов и программ отображения массива входных данных на состояния и динамику их эволюции под влиянием управляющих факторов. Если эта задача имеет решение, то автоматизированная СППР, оперативно (время принятия решения определяется техническими возможностями вычислителей) идентифицирует состояние объекта, прогнозирует его динамику и определяет управляющие факторы, адекватные целевому (требуемому) состоянию.

## Постановка задачи и методы решения

В настоящее время существуют и успешно применяются в различных задачах интеллектуальные процедуры кластерного анализа, понижения размерности входного вектора, классификации, многоуровневого распознавания, многофакторного тестирования на основе нейросетевых технологий [6]. Нейросетевые модели обладают ASSO-

циативной памятью, что является базой для понижения размерности входного вектора и анализа информативности входных данных. На их основе при определенных условиях в многомерном пространстве управляющих факторов, признаков состояния субъекта и совокупности прецедентов предыстории, удается найти вид разделяющей поверхности в виде модифицированного пространства синаптических коэффициентов. Это обстоятельство может стать основой автоматизации принятия решений при комплексном подходе к реализации базовых функций процесса автоматического управления в нейросетевом базисе и среде стандартных нейроконструкторов [2], [3], [6]. Этап предсказания эволюции состояния объекта с различным горизонтом прогноза нейронная сеть способна интерпретировать как решение задачи нелинейной регрессии (многомерной зависимости). При этом находится вид зависимости состояния субъекта от входных факторов как отображение пространства входных признаков на пространство выходных состояний и реализуется путем итерационных процедур обучения сети на множестве прецедентов. Так как в составе входных воздействий присутствует и вектор управляющих факторов, то заключительный этап – поиск оптимального управления состоянием объекта – может быть сведен к выбору целевой функции и обоснованию надежности и точности решений обоснованием доверительных вероятностей и доверительных интервалов.

Для анализа базовых процессов в СЦБР целесообразно воспользоваться пакетом технического анализа данных StatSoft с нейросетевым модулем STATISTICA Neural Networks [3-5].

## Модели распознавания актуального состояния

Построим модели базовых функций распознавания на примерах – диагностика технического устройства и классификация объекта по геофизическим признакам – и реализуем их в среде нейроэмулятора Statistika Neural Network.

Для принятия решения система распознавания должна иметь аналитическую зависимость «состояние – факторы», когда и первые, и вторые в общем случае являются векторными величинами:

$$|y^k| = F |x^m|. \quad (3)$$

Необходимо найти отображение  $F : X \rightarrow Y, X \subset \mathfrak{R}^m, Y \subset \mathfrak{R}^k$  согласно (1), чтобы по известным значениям вектора входных факторов  $\vec{X} = (x_1, \dots, x_m) \in X$  оценить значения выходного вектора  $\vec{Y} = (y_1, \dots, y_k) \in Y$ . Оператор  $F$  включает в себя все процедуры преобразований пространства  $\vec{X} = (x_1, \dots, x_m) \in X$  в пространство  $\vec{Y} = (y_1, \dots, y_k) \in Y$ .

В нейросетевом формате задача может быть представлена в виде [7]:

$$y^k(x^m) = \sum_{j=1}^H v_j (w_{j1}x_1 + w_{j2}x_2 + \dots + w_{jm}x_m + u_j), \quad (4)$$

где  $y^k$  – вектор состояний (классов);  $k$  – номер индикатора состояний (имя признака);  $x^m$  – вектор факторов (словарь признаков).

Пространство признаков, описывающих образ исследуемого изделия и характеризующих его состояние, определено по условию задачи. Оценка этого вектора характеризует текущее состояние объекта. Если состояния объекта исследования описать на

языке информативных признаков как алфавит классов, то для каждого из них можно поставить в соответствие определенный словарь признаков. Тогда отображение входного вектора на выходные состояния следует рассматривать как задачу распознавания образов. При определенных условиях она может быть сведена к модификации синаптического пространства нейросети как к процедуре обучения с учителем и решена в среде стандартных нейроэмуляторов. Примером реализации нейросетевой модели распознавания может служить модель технической диагностики радиотехнического устройства [8]. Для распознавания состояния объекта составлен словарь информативных признаков и описан алфавит классов состояний объекта на языке этого словаря. Основными показателями, характеризующими состояние исследуемого объекта, являются замеры контрольно-измерительной аппаратуры в формате словаря признаков. Эталонное состояние объекта характеризуется набором приведенных среднестатистических норм в формате тех же пространств информативных признаков. Так как каждому классу соответствует свой набор показателей, то процедура классификации объекта сводится к анализу пространства признаков текущего состояния и сравнения результатов анализа с описаниями выбранных классов. В результате интерактивного диалога получен ансамбль моделей сетей, осуществлено обучение, выбран наиболее производительный вариант, представленный на рис. 1.

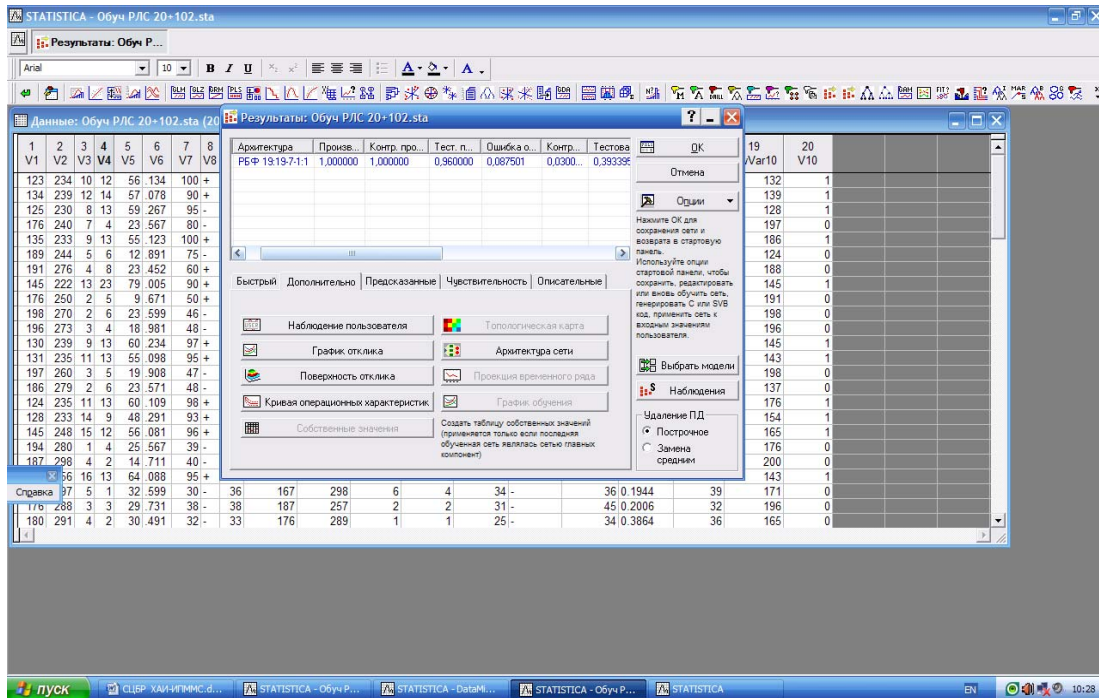


Рисунок 1 – Фрагмент обучающей выборки и параметры модели

В нейросетевом формате задача распознавания классов текущего состояния исследуемого субъекта решена с использованием дельта-правила [6] и квадратичной функции ошибки

$$E(w) = \sum_{k=1}^P (d^k - y^k)^2, \tag{5}$$

где  $P$  – размерность вектора входных параметров;  $y^k$  – реальный выход сети для  $k$ -го признака;  $d^k$  – эталонный (целевой) выход сети для  $k$ -го признака;  $w$  – массив

синаптических коэффициентов. При установлении аналитического вида  $y^k$  и  $d^k$  использованы процедуры выбора ошибки обучения с учетом допустимых рисков в предметной области через статистические критерии согласия, а динамика индикаторов текущего и целевого состояний описана в виде [9]:

$$y_m(X) = \frac{1}{mL} \sum_{i=1}^m \sum_{l=1}^L I(X_{il} \geq x_{il}), \quad (6)$$

$$d_m(X) = \frac{1}{mK} \sum_{i=1}^m \sum_{k=1}^K [I(X_{ik} \geq d_k^{\min}) - I(X_{ik} \leq d_k^{\max})], \quad (7)$$

где  $I(X_{il} \geq x_{il}) = \begin{cases} 1, & \text{если } X_{il} \geq x_{il} \\ 0, & \text{если } X_{il} < x_{il} \end{cases}$ ;  $i = \overline{1, m}$ ;  $l = \overline{1, L}$  – номер управляющего

фактора;  $L$  – количество управляющих факторов;  $X = \{X_{il}\}$  – наблюдаемые значения  $l$ -го управляющего фактора для  $i$ -й выборки,  $d_k^{\min}$  и  $d_k^{\max}$  – границы интервалов допустимых значений индикаторов вектора целевого состояния (выбираются из условия допустимых рисков в предметной области). При наличии двух классов состояний формирование обучающего множества упрощается. Таким образом, на данном примере показана реализация базовых функций, относящихся к решению задачи распознавания ситуаций или состояний объекта.

## Модели кластерного анализа данных

Следующая группа задач решается моделями кластерного анализа в контексте нахождения однородных подмножеств в данных. Эта процедура необходима при автоматизации процесса описания классов на языке признаков и при нахождении однородных групп в задаче прогноза на основе многомерной регрессии. Покажем на примере анализа данных экологического мониторинга.

Имеется конечный массив обучающих выборок  $X^n = \{x_1, x_2, \dots, x_n\} \subset X$ . Известен вид функции расстояния между объектами  $\rho(x, x^*)$  (евклидово расстояние). Необходимо разделить массив данных на непересекающиеся подмножества так, чтобы каждое состояло из объектов, близких по метрике  $\rho(x, x^*)$ , а объекты разных подмножеств существенно отличались между собой, то есть:

$$\sum_i^n d(X_i, \bar{X}_j) \Rightarrow \min; \quad (8)$$

$$\sum_j^K d(\bar{X}_h, \bar{X}_j) \Rightarrow \max, \quad (9)$$

$$\vec{X} = (x_1, \dots, x_n) \in X; \quad \vec{K} = (k_1, \dots, k_j) \in K,$$

где  $X$  – множество выборок признаков описания инвестиционных состояний;  $K$  – множество номеров кластеров;  $\vec{X} = (x_1, \dots, x_m) \in X$ ;  $\vec{K} = (k_1, \dots, k_j) \in K$  – множества значений

входных факторов и номеров классов;  $h, j = 1, 2, \dots, K$  – средние значения в кластерах;

$d(X_i, \bar{X}_j)$  – расстояние между объектом и центром кластера;  $d(\bar{X}_h, \bar{X}_j)$  – расстояние между центрами кластеров.

Воспользуемся обобщенными показателями экологического мониторинга на примере региональных данных [10], составим исходную таблицу данных в пакете технического анализа Statsoft (Statistika 6.1) и проведем кластеризацию данных в пространстве наблюдений (строк) для стандартизованных данных. Результатом стандартизации является приведение всех переменных к единой шкале: данные изменяются в пределах нуля в диапазоне  $\pm 3$ , причем большая часть всех значений будет принадлежать интервалу  $(-1, 1)$ . Процедура стандартизации не изменяет структуру взаимодействий между переменными, не влияет на структуру кластеров. Результат кластеризации представлен на рис. 2.

Элементы кластера номер 1 (РЕЗУЛЬТАТ ЭКОЛОГИЧ и расстояния до центра кластера. Кластер содержит 95 набл.						
	3	4	5	6	7	
Расст.	356,3160	902,6745	348,7101	201,4843	329,9767	271
Элементы кластера номер 2 (РЕЗУЛЬТАТ ЭКОЛОГИЧ и расстояния до центра кластера. Кластер содержит 232 набл.						
	Var1	2	101	102	103	1
Расст.	710,9604	710,9604	39,85736	80,80621	343,3665	194
Элементы кластера номер 3 (РЕЗУЛЬТАТ ЭКОЛОГИЧ и расстояния до центра кластера. Кластер содержит 15 набл.						
	26	51	76	118	119	1
Расст.	1259,087	886,3760	948,9191	435,3337	661,3876	281

Рисунок 2 – Кластеры в данных экологического мониторинга региона

Анализ результатов позволяет утверждать, что все множество данных хорошо разделяется на три кластера. Стоит отметить, что данные таблиц хорошо иллюстрируют их устойчивую группировку внутри кластеров и надежное разделение наблюдений на однородные группы между кластерами. Алгоритмы, реализующие процедуры группировки данных, обеспечивают однородность данных внутри кластеров и максимальную отдаленность самих кластеров [6]. Следовательно, условия (8) и (9) при выполнении процедуры формирования однородных групп в исходных данных соблюдены. Решив задачу кластерного анализа и добившись однородности данных выборок в каждом подмножестве, зависимость «вход – выход», можно переходить к задаче многомерной регрессии.

## Модели многомерной регрессии

В случае большого количества разнородных данных (формат ССТС) для каждого из кластеров предстоит построить отдельную нейронную сеть для многомерной регрессии. В данном случае получим физическую модель техногенной нагрузки как реализацию функции (1). Если производительность сети и ошибки на обучающем, контрольном

и тестовом множестве в допустимых пределах, то модель становится инструментом поддержки принятия решений в оценке техногенной ситуации в регионе. Так как задача регрессии решается внутри каждого кластера, то наблюдения соответствующего кластера используем в задаче многомерного регрессионного анализа. Второй этап реализует процедуру построения многомерной регрессии в режиме «обучения с учителем» [6]. При этом процедура обучения сети выполняется итерационно по алгоритму обратного распространения ошибки применительно к данным формата экологической нагрузки региона:

$$\frac{1}{mn} \sum_{j=1}^n \sum_{i=1}^m (y_{ij} - d_{ij})^2 \Rightarrow \min, \quad (10)$$

где  $y_{ij}$  – вектор индикаторов выходных состояний (рис. 1);

$d_{ij}$  – результат обучения сети на  $j$ -выходе, при  $i$ -м примере обучающей выборки;

$j = 1, n$  – номер выхода сети;

$i = 1, m$  – номер примера;

$m, n$  – размерность массива примеров и числа выходных элементов сети.

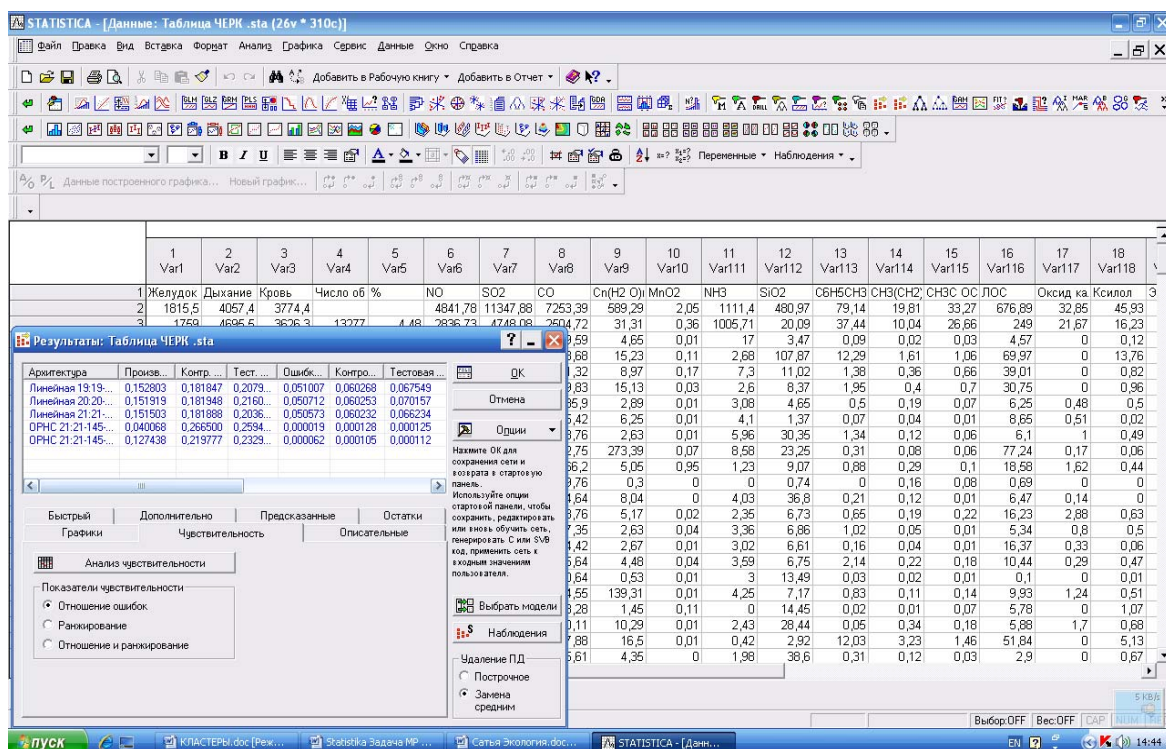


Рисунок 3 – Профили моделей и фрагмент обучающей выборки

Анализ профилей результатов моделирования позволяет выделить сети с приемлемыми для практики производительностью и ошибками на обучающих, контрольных и тестовых множествах. Это свидетельствует об адекватности математической модели физическому содержанию исследуемого процесса. На примере кластера № 2 приведен графический результат построения многомерной регрессионной зависимости для пяти моделей (рис. 4).



Найденная регрессионная зависимость устанавливает связь входных факторов и выходных индикаторов системы через массивы синаптических коэффициентов пяти обученных нейросетевых моделей. Производительность моделей представлена на рис. 5.

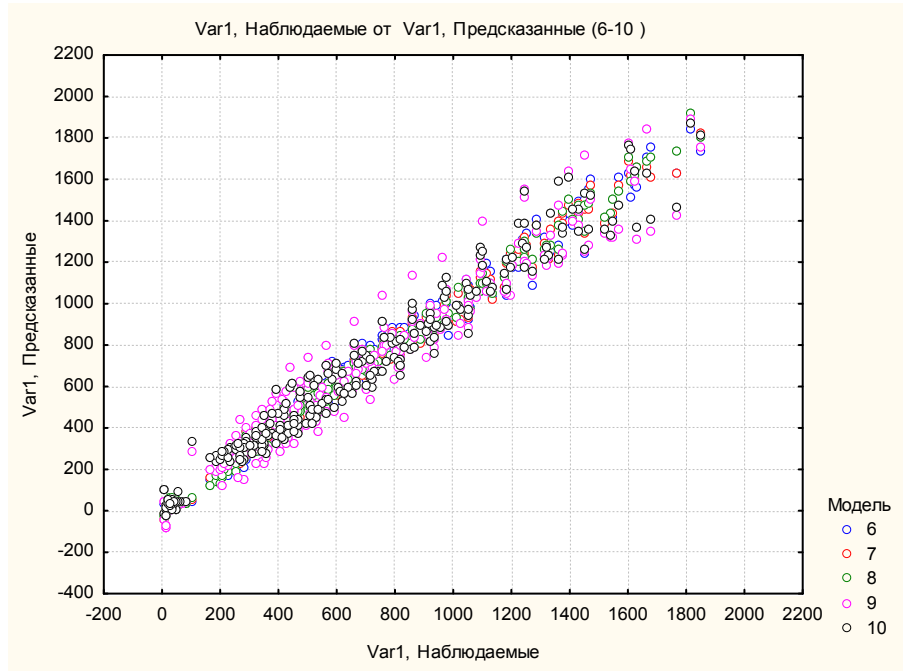


Рисунок 4 – Характеристика качества многомерной регрессии

Результаты работы моделей (Полтавська область.stw)										
N	Архитектура	Производительность обуч.	Контр. производительность	Тест. производительность	Ошибка обучения	Контрольная ошибка	Тестовая ошибка	Входы	Скрытые(1)	Скрытые(2)
1	РБФ 17:17-4-1:1	0,096655	0,066709	0,143559	0,079432	0,050451	0,051091	17	4	0
2	МП 10:10-5-1:1	0,085117	0,103619	0,469839	0,033707	0,028942	0,067853	10	5	0
3	Линейная 16:16-1:1	0,000000	0,071421	0,256897	0,000000	0,022746	0,050861	16	0	0
4	Линейная 17:17-1:1	0,000000	0,069870	0,251321	0,000000	0,022252	0,049757	17	0	0
5	МП 5:5-3-1:1	0,039115	0,081631	0,258584	0,013231	0,021307	0,038857	5	3	0

Рисунок 5 – Показатели производительности моделей

Сеть распознала структуру обучающего множества и пригодна для использования в прогнозировании значений зависимой переменной. Таким образом, математические модели базовых функций автоматизированных СППР для ССТС и объектов критической инфраструктуры реализуются в среде стандартного нейропакета в режиме реального времени.

### Обоснование надежности и точности результатов моделирования

Под производительностью в задачах классификации и прогноза подразумевается доля правильно классифицируемых наблюдений по отношению к общему числу наблюдений, что при достаточной выборке приближает частоты наблюдений к вероятностям. В задачах классификации и прогнозирования выбран нейроэмулятор Statistika Neural Network, который определяет вероятность принадлежности предъявленного образа к каждому из классов. В формате рассматриваемой задачи это ре-

шающее условие, так как обеспечивает искомый результат, ведь в данном контексте это адекватно вероятности правильного решения. В работе [11] приведено обоснование надежности и точности решения подробных задач и показано, что построенные модели реализации базовых функций для СППР с применением нейропакетов технического анализа [12] позволяют классифицировать состояния и строить прогнозы поведения объектов по критерию максимальной апостериорной вероятности. При этом сделан вывод о равноценной надежности получаемых решений при коллективном голосовании, если технические средства реализуют оптимальные статистические правила или интеллектуальные нейросетевые технологии. В рамках данной задачи этот факт позволяет утверждать, что с практической точки зрения СППР критических инфраструктур приобретают новое качество, которое проявляется в наличие технического инструмента принятия состоятельных решений в режиме реального времени.

## Выводы

1. Нейросетевой базис быстрого реагирования для СППР критических инфраструктур позволяет реализовать базовые функции классификации, кластерного анализа и прогнозирования на основе многомерной регрессии в режиме реального времени с надежностью, не уступающей традиционным методам математической статистики.

2. Практическая значимость результатов исследования состоит в автоматизации функций СППР и снижении рисков в принятых решениях за счет создания дополнительного нейросетевого «эксперта» в системах принятия коллективных статистических решений взвешенным голосованием.

## Литература

1. Бусленко Н.П. Моделирование сложных систем / Бусленко Н.П. – [2-е изд.]. – М. : Наука, 1978. – 400с.
2. Морозов А.А. Ситуационное управление и системы поддержки принятия решений / А.А. Морозов, Г.С. Теслер // Системи підтримки прийняття рішень. Теорія і практика : зб. доповідей науково-практичної конференції. ІПММС НАН України. – Київ, 2005. – С. 5-9.
3. Морозов А.А. Состояние и перспективы нейросетевого моделирования СППР в сложных социотехнических системах / В.П. Клименко, А.Л. Ляхов, С.П. Алёшин // Математичні машини і системи. – 2010. – № 1. – С. 127-149.
4. Ляхов А.Л. Сложная социотехническая система как объект управления искусственной нейронной сетью / А.Л. Ляхов, С.П. Алёшин // Вісник інженерної академії України. – 2010. – № 1. – С. 93-97.
5. Ляхов А.Л. Гарантиоспособные технологии принятия решений ситуационными центрами быстрого реагирования / А.Л. Ляхов, С.П. Алёшин // Математическое и имитационное моделирование систем. МОДС'2010 : сб. докладов V-й научно-практической конференции с международным участием / ИПММС НАУ Украины. – Киев, 2010. – С. 199-201.
6. Хайкин С. Нейронные сети: полный курс / Хайкин С. ; [пер. с англ.]. – [2-е изд.]. – М. : Издательский дом «Вильямс», 2006. – 1104 с.
7. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиций непрерывных функций одного переменного и сложения / Колмогоров А.Н. // Доклады АН СССР. – 1957. – Т. 114. – С. 953-956.
8. Ляхов А.Л. Техническая диагностика бортовых радиолокационных систем в среде Statistika Neural Network / А.Л.Ляхов, С.П. Алёшин // Радіоелектронні і комп'ютерні системи. – 2010. – № 7(48). – С. 195-199.
9. Ляхов А.Л. Искусственная нейронная сеть как измерительный инструмент адекватности модели с адаптивным классом точности / А.Л. Ляхов, С.П. Алёшин // Математичні машини і системи. – 2010. – № 2. – С. 61-66.
10. Голуб С.В. Методологія створення автоматизованих систем багаторівневого соціоекологічного моніторингу : автореф. дис. на здобуття наукового ступеня д-ра техн. наук : спец. 05.13.06 / С.В. Голуб. – Київ, 2008. – 35 с.

11. Алёшин С.П. Нейросетевое распознавание классов в пространстве физиологических признаков биосенсоров / С.П. Алёшин // Искусственный интеллект. – 2010. – № 4. – С. 644-650.
12. Боровиков В.П. STATISTICA NN – Техническое описание / Боровиков В.П. – М. : Мир, 1999. – 239 с.

## Literatura

1. Buslenko N.P. Moscow : Nauka.1978. 400 p.
2. Morozov A.A. Zbirnyk dopovidej naukovo-praktychnoi konferencii. IPMMS NAN Ukraini / Systemy pidtrymky priijnattja rishen'. Teorija i praktika.Kiev. 2005. P. 5-9
3. Morozov A.A. Matematychni mashyny i systemy. 2010.№ 1. P. 127-149.
4. Ljahov A.L. Visnyk inzhenernoi akademii Ukraini. 2010. № 1. P. 93-97.
5. Ljahov A.L. V-ja nauchno-prakticheskaja konferencija s mezhdunarodnym uchastiem «Matematicheskoe i imitacionnoe modelirovanie sistem. MODS' 2010». Sbornik dokladov: IPMMS NAU Ukrainy. Kiev. 2010. P. 199-201.
6. Hajkin S. Moscow: Vil'jams. 2006. 1104 p.
7. Kolmogorov A.N. Doklady AN SSSR.1957. Vol. 114. P. 953-956
8. Ljahov A.L. Radioelektronni i komp'juterni systemy. 2010. № 7(48). P. 195-199
9. Ljahov A.L. Matematychni mashyny i systemy. 2010. №2. P. 61-66.
10. Golub S.V. Avtoref. dys. na zdobuttja naukovogo stupenja d-ra tehn. nauk: 05.13.06. Kiev. 2008. 35 p.
11. Aljoshin S.P. Iskusstvennyj intellekt. 2010. № 4. P. 644-650.
12. Borovikov V.P. STATISTICA NN -Tehnicheskoe opisanie. Moscow: Mir.1999. 239 p.

### *С.П. Альошин*

#### **Нейромережні моделі прийняття рішень швидкого реагування для критичної інфраструктури**

Робота присвячена проблемі автоматизації прийняття рішень в режимі реального часу для складних соціотехнічних об'єктів у базисі емуляторів нейросередовища. Запропоновано технологію моделювання базових процесів автоматизації прийняття рішень (розпізнавання станів, виділення однорідних даних, прогнозування динаміки поведінки) для критичних інфраструктур у різних предметних галузях. В основі підходу лежить ідея створення додаткового, незалежного інструменту прийняття рішення в режимі реального часу. Наведені моделі та алгоритми реалізовані в середовищі стандартних нейроемуляторів формату Statistika Neural Network, що забезпечують слушні показники надійності прийнятих рішень.

### *S.P. Aleshin*

#### **Neural Network Models of Decision-Making of Fast Reaction for Critical Infrastructures**

The article is devoted to the problem automatic decision-making in a mode of real time for difficult objects on basis of neural network emulators. The technology of modeling of base processes of automation of decision-making (recognition of conditions, allocation of the homogeneous data, forecasting of dynamics of behavior) for critical infrastructures in different subject domains is offered. At the heart of the approach there is the idea of creation of the additional, independent tool of decision-making in a mode of real time. The models and algorithms realized in the environment of standard emulators format Statistika Neural Network, providing well-founded indicators of reliability of accepted decisions are resulted.

*Статья поступила в редакцию 23.03.2011.*