

УДК 004.032.26

**МОДЕЛЬ НЕЙРОСЕТЕВОГО АНАЛИЗА ТЕХНИЧЕСКОГО
СОСТОЯНИЯ СЛОЖНОЙ СИСТЕМЫ**

Бутина Т.А.

кандидат физико-математических наук, доцент

*Московский Государственный Технический Университет им. Н.Э.Баумана
(национальный исследовательский университет)*

Москва, Россия

Дубровин В.М.

кандидат технических наук, доцент

*Московский Государственный Технический Университет им. Н.Э.Баумана
(национальный исследовательский университет)*

Москва, Россия

Семенов К.С.

*специалист в области управления сложными техническими системами,
инженер I категории*

*Ракетно-космическая корпорация "Энергия", Центр Управления Полетами
Москва, Россия*

Аннотация

В статье предложен метод обучения нейронной сети, позволяющий с достаточной для практики точностью интерпретировать результаты испытаний или результаты, полученные при эксплуатации сложной технической системы с большим числом входных сигналов. При этом использовался метод нейросетевой диагностики состояния технической системы, построенный на разбиении множества признаков состояний системы на конечное число отдельных подмножеств, что дает возможность в режиме реального времени с заданной вероятностью осуществлять диагностику состояния системы. В работе определено также требование к

проведению моделирования работы технической системы для получения заданной величины среднеквадратической ошибки при оценке параметров системы. Оценка общего состояния технической системы и способности её выполнять весь комплекс задач, предусмотренных программой испытаний или эксплуатации, осуществляется на основе данных первичной информации. Решение задачи осложняется чаще всего нечёткостью и размытостью входящей первичной информации (в том числе телеметрических данных) о состоянии технической системы, большом числе этих данных и необходимости обработки этих данных за короткий период времени. Такие задачи имеют место, например, в атомной промышленности, электроэнергетике и космонавтике, когда ведётся непрерывный контроль технического состояния ядерных силовых установок, электросиловых установок и космических объектов. Оптимально решать эти задачи возможно только с использованием автоматизированного анализа состояния сложной технической системы, состоящей из большого количества элементов, подлежащих контролю. Под автоматизированным контролем понимается программа обработки данных, выделенных из всего потока первичной информации и представления результатов обработки для дальнейшего анализа и принятия решения.

Ключевые слова: Техническая система, нейронная сеть, парадигма, нейроны, классификатор, слой нейронов, дизъюнкт, структура нейронной сети, вес сигнала.

MODELING OF COMPLEX TECHNICAL DIAGNOSTICS SYSTEMS BASED ON MULTILAYER NEURAL NETWORK

Butina T.A.

Candidate of Physics and Mathematics, Associate Professor

Bauman Moscow State Technical University

Дневник науки | www.dnevniknauki.ru | СМИ Эл № ФС 77-68405 ISSN 2541-8327

Moscow, Russia

Dubrovin V.M.

Candidate of Technical Sciences, associate professor

Bauman Moscow State Technical University

Moscow, Russia

Semenov K.S.

Specialist in the management of complex technical systems, 1st category engineer

Rocket and Space Corporation "Energia", The Mission Control Center

Moscow, Russia

Annotation

The article proposes a neural network training method that allows interpreting test results or results obtained during operation of a complex technical system with a large number of input signals with sufficient accuracy for practice. At the same time, the method of neural network diagnostics of the state of a technical system was used, based on the division of a set of signs of system states into a finite number of separate subsets, which makes it possible to diagnose the state of the system in real time with a given probability. The paper also defines the requirement for modeling the operation of a technical system in order to obtain a given value of the RMS error when evaluating system parameters. A method for the automated analysis of complex technical system, consisting of a large number of elements to be controlled. Under the automated control program refers to data extracted from the total amount of raw primary data processing and presentation of results for further analysis and decision making. By means of automated control means the program developed by implementing testing methods.

Keywords

Technical system, neural network paradigm, neurons, classifier, a layer of neurons, disjunction, neural network structure, the weight signal.

Введение

Постоянное развитие технических систем и усложнение условий их эксплуатации сопровождается увеличением количества контролируемых параметров, определяющих работоспособность системы. При этом большая часть информации не проходит обработку, а поступает непосредственно от работающей системы к оператору без предварительного анализа. В этих условиях оператору следует оценить состояние технической системы и принять решение по её дальнейшей эксплуатации. Эта задача может быть решена средствами автоматизированного контроля на основе многослойной нейронной сети [1,2,3].

Нейронная сеть состоит из одиночных функциональных элементов – нейронов, объединённых между собой каналами синаптических связей. Развитие в области нейронауки следует по пути расширения [4,5] функциональных возможностей как отдельного нейронного элемента, так и строящихся на его основе нейронных сетей. Функциональной основой нейрокомпьютера является воспроизводимая им модель нейронной сети – нейропарадигма. В настоящее время разработаны и нашли практическое применение при построении нейрокомпьютерных систем несколько моделей нейронных систем (парадигм), каждая из которых ориентирована на решение определенного класса прикладных задач [6,7,8,9]. В настоящей работе предложена модель многослойной нейронной сети, обучаемой методом обратного распространения ошибки. Одним из важных свойств этой модели является то, что алгоритм её обучения сходится за конечное число шагов, и она может при числе слоёв обучаемых нейроэлементов большем или равным трём строить функции дискриминанта любой требуемой сложности и любой требуемой точности приближения. Более всего специфике решаемой задачи отвечает нейропарадигма в виде многослойной нейронной сети, обучаемой методом обратного распространения ошибки.

При этом предполагается использование нейронной сети для анализа
Дневник науки | www.dnevniknauki.ru | СМИ Эл № ФС 77-68405 ISSN 2541-8327

первичной информации с учётом следующих ограничений [10,11,12]:

- работа в реальном времени, в условиях жёсткого лимита времени принятия решений, ограниченного вычислительными возможностями, а также неопределенностью, связанной с неполнотой и противоречивостью поступившей информации;
- непрерывный режим функционирования в течение длительного времени;
- минимизация участия оператора в процессе управления технической системой;
- качественное и своевременное диагностирование состояния технической системы за время, адекватное времени, за которое можно предотвратить отказ оборудования.

Алгоритм нейросетевого анализа

Нейронную сеть можно представить как взвешенный направленный граф, узлы (нейроны) которого расположены слоями. При этом узел одного слоя имеет связи со всеми узлами предыдущего слоя, внутри каждого слоя нейроны связей не имеют, т.е. граф имеет входной, скрытые и выходной слой. Такая модель выполняет роль классификатора диагностики состояния технической системы [13,14]. Классификатор имеет несколько входов, на которые подаются данные для анализа и несколько выходов, каждый из которых соответствует определенному классу распознаваемых объектов. Вначале формируется входной вектор, состоящий из значений параметров, характеризующих состояние системы. Далее он передаётся на вход нейросетевого классификатора и начинается процесс распознавания. В результате каждый нейроэлемент выходного слоя формирует выходной сигнал соответствующего уровня. Наибольший по уровню из выходных сигналов указывает на класс, к которому принадлежит распознаваемый входной вектор параметров. Таким образом, первый (входной) слой отвечает

Дневник науки | www.dnevniknauki.ru | СМИ Эл № ФС 77-68405 ISSN 2541-8327

за получение входящей информации, а все последующие слои – за обработку этих данных, результаты которой выдаёт выходной слой. Структура нейронной сети представлена на рис.1.

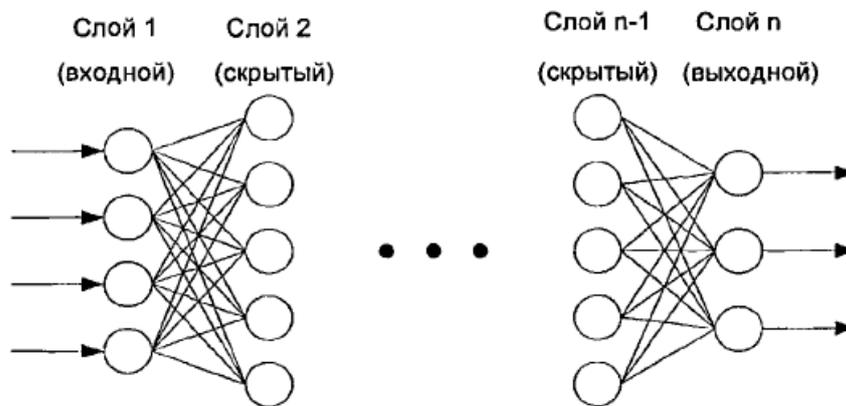


Рис.1 Структура нейронной сети (рис. автора)

Каждый узел (нейрон) состоит из нескольких входов (синапсов), сумматора, нелинейного преобразователя и выхода. На входы нейрона подаются сигналы с выходов нейронов предыдущего слоя. Эти сигналы умножаются на вес соответствующего сигнала и поступают в сумматор. Сигнал из сумматора подается на вход нелинейного преобразователя, который реализует функцию активации нейрона. В качестве элементов нейронной сети используется модель нейрона в виде:

$$P_{j,m}^z = \sum_{i=1}^n x_{i,m}^{z-1} \gamma_{i,j,m}^z$$

$$x_{j,m}^z = \sigma(P_{j,m}^z)$$

где $x_{j,m}^{z-1}$ – входные воздействия, поступающие с выходов i нейронов предыдущего $z-1$ слоя на входы j нейрона z слоя в момент времени m ;

$x_{j,m}^z$ – выходной сигнал j нейрона слоя z в момент времени m ;

$\gamma_{i,j,m}^z$ – синаптический вес i входа j нейрона слоя z в момент времени m .

Алгоритм обучения нейронной сети

Для того чтобы нейронная сеть могла корректно определять состояние технической системы, сеть необходимо обучить. Для этого ей представляется некоторый набор входных векторов и связанный с ним набор выходных векторов. Входной вектор представляет собой последовательность параметров, характеризующих состояние технической системы в определенный момент времени с указанием типа состояния. Выходной вектор представляет собой список выходов нейросети и желаемые значения на них [15,16].

В процессе обучения осуществляется подбор таких величин синаптических весов, при которых обеспечивается минимизация функции ошибки, т.е. получение требуемого вектора выходных сигналов при заданном входном векторе. При этом рассматривается суммарная функция ошибок, которая минимизируется по всему пакету входных векторов.

Чередование процедур прямого и обратного распространения сигналов при предъявлении каждого входного вектора \vec{x}_m и желаемого выходного вектора \vec{y}_m составляет суть обучения нейронной сети методом обратного распространения ошибки. Синаптические веса обучаемых нейронов выходного и скрытых слоёв модифицируются после предъявления каждой пары векторов \vec{x}_m, \vec{y}_m , либо в режиме пакетного обучения, после предъявления всего пакета векторов \vec{x}_m, \vec{y}_m ($m=1,2..m$), а до этого момента получаемые приращения синаптических весов накапливаются каждое в отдельности.

Для обучения конкретному пакету входных векторов требуется некоторое количество итераций, т.е. серий предъявления этого пакета, что позволяет получить минимум суммарной ошибки и нейросеть будет обучена требуемой функции.

Метод нейросетевой диагностики состояния технической системы

Для решения задачи диагностики технической системы множество состояний системы разбивается на отдельные подмножества признаков состояния, Дневник науки | www.dnevniknauki.ru | СМИ Эл № ФС 77-68405 ISSN 2541-8327

каждое из которых распознается отдельной нейронной сетью. Это позволяет при фиксированных аппаратных затратах распознавать состояние системы с заданной вероятностью.

Пусть X – множество состояний системы мощности N . Тогда 2^N – мощность всех подмножеств множества X , которые могут быть использованы для обучения сети. Поскольку число разбиений множества X конечно, то задача диагностики системы может быть решена за конечное число шагов, то есть при фиксированных аппаратно-временных затратах. Для решения задачи оперативной диагностики состояния технической системы использовались нейронные сети с тремя слоями, так как такие сети способны разграничивать области любой сложности.

Для разделения данных на классы используются нейроны первого скрытого слоя V_{ij} (разграничивающие плоскости) вида

$$V_{ij} = A_{i0} - Z_{ij}, \quad i_j = 1, 2, \dots, k_j,$$

где k_j – количество разграничивающих плоскостей первого слоя.

В случае невыпуклых областей используются нейроны второго скрытого слоя C_{i_2} , $i_2 = 1, 2, \dots, k_2$, k_2 – количество требуемых дизъюнктов для реализации правил. В каждом слое нейронной сети находятся нейроны D_{i_3} , $i_3 = 1, 2, \dots, k_3$, где k_3 – количество входов нейронной сети. В этом случае выходы нейронной сети могут быть вычислены по формуле

$$D_{i_3} = F_a(\sum_{i_2=1}^{k_2} W_{3,i_3,i_2} \cdot F_a(\sum_{i_1=1}^{k_1} W_{2,i_2,i_1} \cdot F_a(\sum_{i_0=1}^{k_0} W_{1,i_1,i_0}))),$$

где $F_a(x)$ – пороговая функция активации,

$$F(x) = \begin{cases} 1, & \text{при } x > 0, \\ -1, & \text{при } x \leq 0; \end{cases}$$

$W_{k,i_k,i_{k-1}}$ – веса нейронной сети, означающие вес нейронной сети от j -го в $k-1$ слое к i нейрону в k -ом слое,

A_{i0} – нейроны входного слоя.

Логические выражения задаются для каждого слоя в виде дизъюнктивной

нормальной формы вида:

$$D_{i_3} = \bigcup_{i_3=1}^{k_3} W_{3,i_3,i_2} \cap C_{i_2},$$

$W_{3,i_3,i_2} = 0$, если C_{i_2} не влияет на правило D_{i_3} ,

$W_{3,i_3,i_2} = 1$, если C_{i_2} влияет на правило D_{i_3} ,

$$C_{i_2} = \bigcap_{i_2=1}^{k_2} \|W_{2,i_2,i_1} - 1\| \cup B_{i_1},$$

$W_{2,i_2,i_1} = 0$, если B_{i_1} не влияет на дизъюнкт C_{i_2} ,

$W_{2,i_2,i_1} = 1$, если B_{i_1} влияет на дизъюнкт C_{i_2} и $B_{i_1} > 0$,

$W_{2,i_2,i_1} = -1$, если B_{i_1} влияет на дизъюнкт C_{i_2} и $B_{i_1} \leq 0$.

Величина B_{i_1} может быть представлена в виде

$$B_{i_1} = \sum_{i_0=1}^{k_0} A_{i_0} W_{1,i_1,i_0} - Z_{i_1}$$

Смещение во всех слоях системы имеет вид:

– первый слой

$$W_{1,i_1,k_0+1} = 1 - \frac{2Z_{i_1}}{\max_{i_0} - \min_{i_0}},$$

где $i_0 = \sum_{j=1}^{k_0} j W_{1,i_1,j}$,

\max_{i_0} – максимальное значение параметра,

\min_{i_0} – минимальное значение параметра;

– второй слой

$$W_{2,i_2,k_1+1} = -\sum_{j=1}^{k_1} |W_{2,i_2,j}| + 0,5, \quad i_2 = 1, 2, \dots, k_2;$$

– третий слой

$$W_{3,i_3,k_2+1} = -\sum_{j=1}^{k_2} \left| |W_{3,i_3,j}| - 0,5 \right| +, \quad i_3 = 1, 2, \dots, k_3;$$

Представленный метод нейросетевой интерпретации правил

функционирования сложной технической системы позволяет эффективно в режиме реального времени осуществить диагностику состояния технической системы.

Алгоритм нейросетевого анализа состояния технической системы

Решение задачи диагностики состояния технической системы включает в себя следующие этапы:

1. Задаются произвольные значения весов и порогов для всех нейронов сети, то есть получают пару эталонных векторов входа и выхода.
2. Подаются на входной слой эталонный входной вектор. В каждом слое вычисляются взвешенные суммы S_j всех нейронов по формуле

$$S_j = \sum_k W_{jk} x_k - T_j,$$

где x_k – элемент входного вектора,

W_{jk} – элемент вектора весов нейрона,

T_j – пороговое значение нейрона,

j – номер нейрона в слое,

k – номер входа в j -ый нейрон.

3. Находится выходное значение нейрона y_j как функция активации от взвешенной суммы. В случае, если функцией активации является гиперболический тангенс, это значение равно

$$y_j = th(S_j) = \frac{e^{S_j} - e^{-S_j}}{e^{S_j} + e^{-S_j}}$$

4. Выходное значение y_j нейрона i -го слоя является входным значением x_j нейрона $(i+1)$ -го слоя.
5. Процедуры 2 и 3 повторяются для каждого последующего слоя. В результате будут получены выходные значения y_j каждого нейрона выходного слоя.
6. Для каждого нейрона выходного слоя величина ошибки γ_{ij} будет

определяться по формуле $\gamma_j = y_j - y_j^{эм}$, где

$y_j^{эм}$ – эталонное значение выходного вектора, соответствующее выходному значению j-го нейрона.

7. Вычисляется среднеквадратичная ошибка выходного слоя по формуле

$$E = \frac{1}{2} \sum_j (\gamma_{ij})^2$$

8. Сравняется полученное значение E с заданным изначально. Если ошибка больше заданной, производится послойное (в обратную сторону – от выходного слоя к входному) обучение сети путём изменения весов и порогов.

9. В выходном слое меняются веса и пороги нейронов по формулам:

$$W_{ijk}(t+1) = W_{ijk}(t) - a(t)\gamma_{ij}(1 - y_j^2)x_{ik}; (*)$$

$$T_{ij}(t+1) = T_{ij}(t) + a(t)\gamma_{ij}(1 - y_{ij}^2),$$

$$\text{где } a(t) = \frac{1}{\sum_k x_{ik}^2 + 1}$$

10. Определяется для j-го нейрона взвешенная сумма ошибок из следующего слоя

$$\sigma_{(i+1)j} = \sum_j (w_{(i+1)jk} \gamma_{(i+1)j})$$

11. В каждом скрытом i-ом слое ошибка γ_{ij} j-ого нейрона определяется по формуле: $\gamma_{ij} = \alpha(1 - y_{ij}^2)\sigma_{(i+1)j}$

12. В скрытом i-ом слое изменяются веса и пороги нейронов по формулам (*).

13. Операции (10-12) повторяются для каждого последующего слоя до входного включительно. Таким образом, будет проведена одна итерация обучения нейронной сети.

14. Операции (2-13) повторяются до тех пор, пока получаемая среднеквадратичная ошибка не станет меньше заданной.

Таким образом, нейронная сеть будет обучена по одной паре эталонных векторов.

Для проведения моделирования работы системы рассматривалась трёхслойная нейронная сеть. Было проведено 4 тестовых испытания: на одной, на шести (при различном количестве нейронов в слоях) и на двадцати четырёх выборках. Результаты испытаний представлены в таблице 1.

Таблица 1

№ испытания	Число выборок	Число параметров		Число нейронов в слое	Эталонный вектор	Полученный вектор
		входные	Выходные			
1	1	4	6	5	(0,1,0,0,0)	(0,002; 0,998; 0,002; 0,002; 0,002)
2	6	4	6	5	(0,0,0,1,0,0)	(0,003; 0,001; 0,003; 0,997; 0,000; 0,000)
3	6	4	6	15	(0,0,0,0,0,1)	(0,002; 0,002; 0,001; 0,000; 0,000; 0,997)
4	24	7	9	8	(0,0,0,0,0,0,0,1,1)	(0,001; 0,000; 0,000; 0,002; 0,001; 0,000; 0,001; 0,998; 1,000)

По результатам испытания нейросетевого модуля можно утверждать, что выходной вектор достаточно точно определяет эталонный вектор.

На рис. 2 и 3 представлены графики изменения среднеквадратичной ошибки в зависимости от числа итераций в испытаниях 1 и 4. Как следует из этих графиков число итераций существенно влияет на величину среднеквадратичной ошибки, т. е. повышает точность оценки.

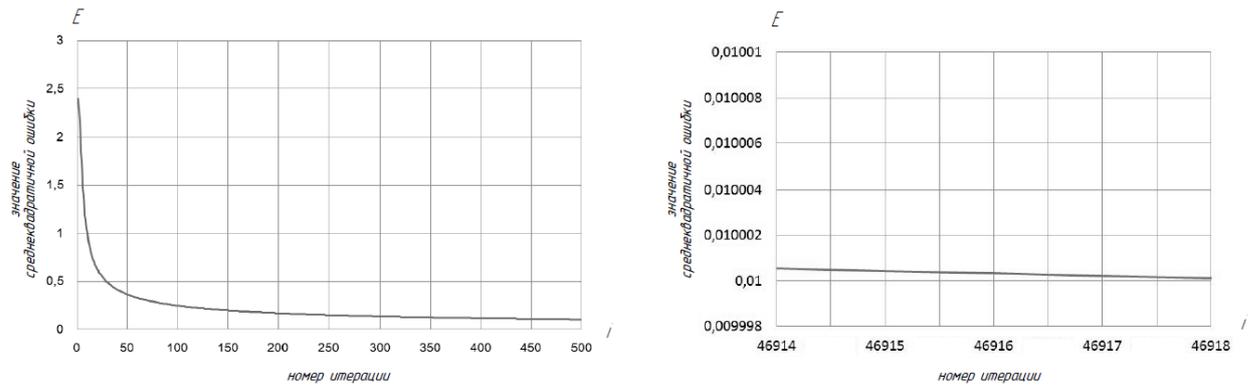


Рис. 2 Графики изменения среднеквадратичной ошибки с увеличением итерации для испытания №1 (рис. автора)

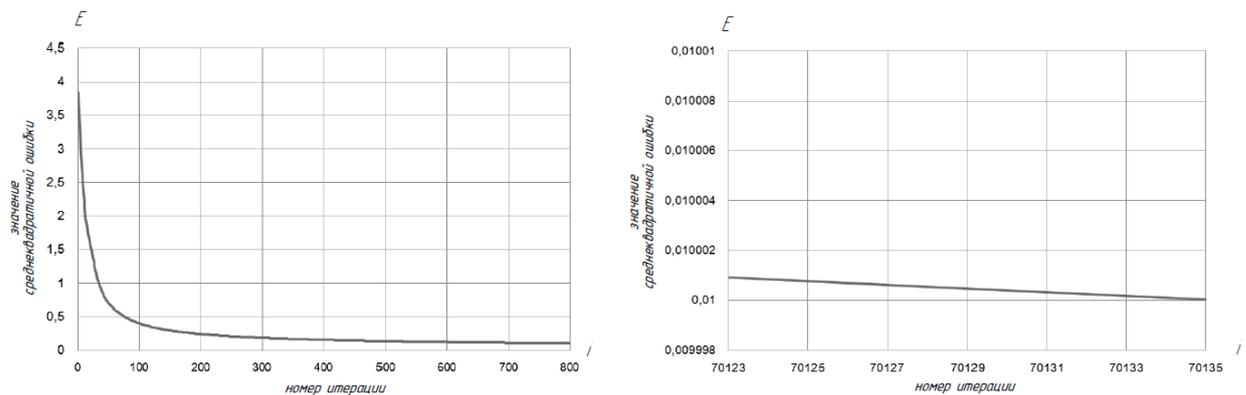


Рис. 3 Графики изменения среднеквадратичной ошибки с увеличением итерации для испытания №4 (рис. автора)

Выводы

1. Предложенный метод нейросетевой диагностики состояния сложной технической системы даёт возможность оперативного контроля этого состояния при следующих ограничениях:

- работа в реальном времени в условиях жёсткого лимита времени принятия решений по предотвращению отказа оборудования;
- минимизация участия оператора в процессе управления технической системой;
- непрерывный режим функционирования в течение длительного времени.

2. При небольшом числе нейронов в слоях для обучения нейронной сети с требуемой точностью необходимо большое число итераций. При большом числе нейронов в слоях таких итераций требуется меньше, однако каждая итерация занимает более продолжительное время. Поэтому размерность нейронов с оптимальным числом итераций и их длительностью может быть получена с помощью проведения тестов в процессе обучения нейронной сети.

Библиографический список

1. Васенков Д.В. Методы обучения искусственных нейронных сетей / Д.В. Васенков // Компьютерные инструменты в образовании. – 2007. - №1 – С. 20-29.
2. Вежневек А. Популярные нейросетевые архитектуры / А. Вежневек // Компьютерная Графика и Мультимедиа Сетевой журнал. – 2004. - №2.
3. Головкин В.А. Нейронные сети: обучение, организация и применение / В.А. Головкин – М.: ИПРЖР, 2001. – 256 с.
4. Дубровин В.М. Алгоритм ускоренного обучения персептронов / В.М. Дубровин, С.А. Субботин // Сборник трудов IV всероссийской научно-технической конференции "Нейроинформатика-2002". – М.: МИФИ, 2002. – 7 с.
5. Клюкин В.И. Нейросетевые структуры и технологии. Часть 1. Электрические и математические модели нейронов. НС прямого распространения. Учебное пособие / В.И. Клюкин, Ю.К. Николаенков // Воронеж: Издательско-полиграфический центр ВГУ, 2008. – 63 с.
6. Коровин Я.С. Методика объяснений нейросетевых решений / Я.С. Коровин // Материалы 4 ежегодной международной научной молодежной конференции ЮНЦ РАН – Изд-во ЮНЦ РАН, 2008. – С. 152-155.
7. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Дневник науки | www.dnevniknauki.ru | СМИ Эл № ФС 77-68405 ISSN 2541-8327

Круглов, В.В. Борисов. – М.: Горячая линия-Телеком, 2002. – 382 с.

8. Потапов В.В. Формальные нейроны как элементы систем автоматического управления и вычислительной техники - Энциклопедия измерений, контроля и автоматизации / В.В. Потапов. - М.: Энергия, 1970. - №14 – С. 41-44.

9. Carpenter G.A. Absolutely stable learning of recognition codes by a self-organizing neural network / G.A. Carpenter // Neural networks Comput. Conf., Snowbird, Utah, Apr 13-16, 1986, N.Y., 1986. – P. 77-85.

10. Fukushima K. Neocognitron: a self-organizing neural network model for a mechanism of visual pattern recognition / K. Fukushima // Lect. Notes Biomath, 1982. – P. 267-285.

11. Hopfield J. Neural computation of decisions in optimization problems / J. Hopfield, D. Tank // Biological Cybernetics, 1985. - Vol 52. – P. 141-142.

12. Marakas G.M. Decision support systems in the twenty-first century / G.M. Marakas // Upper Saddle River, N.J.: Prentice Hall, 1999.

13. Patrick P. Minimisation methods for training feedforward Neural Networks / P. Patrick // NEURAL NETWORKS, 1994. - Vol 7, Number 1 – P. 1-11.

14. Personaz L. A simple selectionist learning rule for neural networks / L. Personaz // Neural Networks Comput. Conf., Snowbird, Utah, Apr 13-16, 1986, N.Y., 1986. – P. 360-363.

15. Personaz L. Designing a neural network satisfying a given of constraints / L. Personaz // Neural Networks Comput Conf., Snowbird, Utah, Apr. 13-16, 1986, N.Y., 1986. – P. 356-359.

16. Power D. J. Web-based and model-driven decision support systems: concepts and issues / D. J. Power // Americas Conference on Information Systems, Long Beach, California, 2000.

Оригинальность 75%