

УДК 004.032.26

**МОДЕЛИРОВАНИЕ ДИАГНОСТИКИ СЛОЖНОЙ ТЕХНИЧЕСКОЙ
СИСТЕМЫ НА ОСНОВЕ МНОГОСЛОЙНОЙ НЕЙРОННОЙ СЕТИ**

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.

Инженер I категории

*Центр Управления Полетами РКК «Энергия,
Королев, Россия*

Аннотация

Нейросеть – это математическая модель в виде программного и аппаратного воплощения, строящаяся на принципах функционирования биологических нейросетей. Эта математическая модель применяется для прогнозирования и распознавания образов, а также для анализа технического состояния систем, состоящих из большого количества элементов. В работе предложен метод 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 решений. Под

средствами автоматизированного контроля понимается программа, реализующая разработанные методы контроля.

При этом в работе рассматривалась схема полносвязной нейронной сети, в которой каждый узел (кроме входного и выходного) выступает как входом, так и выходом, образуя скрытый слой нейронов, и каждый нейрон следующего слоя соединен со всеми нейронами предыдущего слоя. Входы подаются с весами, которые в процессе обучения настраиваются и не меняются в дальнейшем.

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

Moscow, Russia

Dubrovin V.M.

Candidate of Technical Sciences, associate professor

Bauman Moscow State Technical University

Moscow, Russia

Semenov K.S.

1st category engineer,

S.P. Korolev Rocket and Space Corporation Energia,

Korolev, Russia

Abstract

A neural network is a mathematical model in the form of software and hardware implementation, based on the principles of functioning of biological neural networks. This mathematical model is used to predict and recognize patterns, as well as to analyze the technical condition of systems consisting of a large number of elements. The paper proposes a method for automated analysis of the state of a complex technical system consisting of a large number of elements subject to control. Automated control is understood as a program for processing data extracted from the entire flow of primary information and presenting the results of processing for further analysis and decision-making. Automated control means a program that implements the developed control methods.

At the same time, we considered the scheme of a fully connected neural network, in which each node (except for the input and output) acts as an input, and so it goes, forming a hidden layer of neurons, and each neuron of the next layer is connected to all the neurons of the previous layer. The inputs are fed with weights that are adjusted during the training process and do not change in the future.

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

Введение

Нейронные сети представляют собой объединённые между собой каналами синоптических связей однотипные функциональные элементы — нейроны [2;3;7;8]. Развитие в области нейронауки следует по пути расширения функционала как отдельного нейрона, так и нейронных сетей в целом. Нейропарадигма — воспроизводимая нейрокомпьютером модель нейронной сети, его функциональная основа. На сегодняшний день
Дневник науки | www.dnevniknauki.ru | СМИ ЭЛ № ФС 77-68405 ISSN 2541-8327

разработаны и широко применяются при построении нейрокомпьютерных систем несколько моделей нейронных сетей (парадигм). Каждая из этих нейропарадигм ориентирована на решение определённого класса прикладных задач. Чаще всего на практике применяется модель многослойной нейронной сети, обучаемой методом обратного распространения ошибки. Это единственная нейропарадигма, для которой доказано, 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. Данное её свойство предопределило широкое применение нейропарадигмы при решении задач по распознаванию образов и классификации состояний анализируемого объекта. Эта модель и принята в настоящей работе при разработке методов диагностики состояния сложной технической системы, классификации типов возникающих НШС (нештатных ситуаций), выявлении различных состояний системы с целью предотвращения отказов и сокращения времени реакции оператора. Решение задачи осложняется чаще всего нечеткостью и размытостью входящей первичной информации (в том числе телеметрических данных) о состоянии технической системы, большом числе этих данных и необходимостью отработки этих данных за короткий период времени. Это обуславливает использование мощной, достаточно просто обучаемой и быстро работающей нейропарадигмы [4;5;10]. Более всего специфике решаемой задачи отвечает нейропарадигма в виде трехслойной нейронной сети, с обучением методом обратного распространения ошибки.

Схема функциональной структуры нейронной сети

Модель искусственной нейронной сети является классификатором диагностики состояния технической системы. На входы классификатора подаются анализируемые данные, выходов классификатора соответствуют

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

определенному классу распознаваемых состояний объекта. Изначально требуется сформировать входной вектор, включающий значения параметров, характеризующих текущее состояние технической системы. Далее сформированный вектор состояния передается на входы нейросетевого классификатора и запускается процесс распознавания. В результате каждый нейрон выходного слоя формирует выходной сигнал соответствующего уровня [6;9;13]. Наибольший по уровню из выходных сигналов указывает на класс, к которому принадлежит распознаваемый входной вектор [14;15].

Модель нейронной сети представляет собой некоторое множество нейронов, определенным образом соединенных между собой с помощью связей. Нейроны распределены по слоям и внутри каждого слоя связей между собой не имеют. Структура нейронной сети представлена на рис.1.

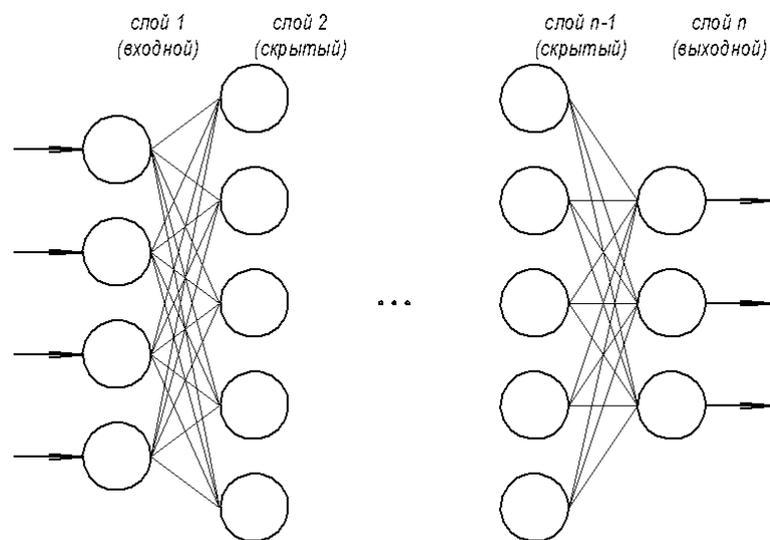


Рис.1 – Структура нейронной сети (рис автора)

Нейрон состоит из нескольких входов (синапсов), сумматора, нелинейного преобразователя и выхода (рис.2)

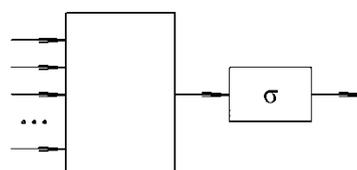


Рис.2 – Структура нейрона (рис автора)

На входы нейрона подается сигнал с выходов нейронов предыдущего слоя. Эти сигналы умножаются на вес соответствующего сигнала и поступают в сумматор. Сигнал из сумматора подается на вход линейного преобразователя, который реализует функции активации нейрона. В качестве элементов нейронной сети используется статическая модель нейрона [10], которая имеет вид:

$$P_{j,m}^z = \sum_{i=1}^n X_{i,m}^{z-1} \gamma_{i,j,m}^z,$$
$$X_{j,m}^z = \sigma(P_{j,m}^z),$$

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 i нейрона z слоя в момент времени m ;

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

Алгоритм функционирования нейронные сети

Для того, чтобы нейронная сеть могла корректно классифицировать состояние технической системы, сеть необходимо обучить. Для этого ей представляется некоторый набор входных векторов и связанных с ним набор выходных векторов [5]. Входной вектор представляет собой последовательность параметров, характеризующих состояние технической системы в определённый момент времени с указанием типа состояния. Выходной вектор представляет собой список выходов нейросети и желаемые значения на них.

В процессе обучения осуществляется подбор таких величин синаптических весов нейрона, при которых обеспечивает минимизации функции ошибок, т.е. получение требуемого вектора выходных сигналов при

заданном входном векторе [1;11;12;16]. 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 входного вектора \vec{Y}_m составляет суть обучения нейронной сети методом обратного распространения ошибки. Синаптические веса обучаемых нейронов выходного и скрытого слоев 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 ($m = 1, 2, \dots, M$), а до этого момента получаемые приращение синаптических весов накапливается каждое в отдельности. Для обучения конкретному пакету входных векторов требуется некоторое количество итерации, 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 расширения задачи диагностики технической системы, множество состояний системы разбивается на отдельные подмножества признаков состояния, каждое из которых распознается отдельной нейронной сетью. Это позволяет при фиксированных аппаратных затратах распознавать состояние системы с заданной вероятностью.

Пусть X – множество состояние системы мощности N , тогда 2^N – мощность всех подмножеств множества X , которые могут быть использованы для обучения нейронной сети. Поскольку число разбиений множества состояний системы конечно, то задача диагностики системы может быть решена за конечное число шагов, то есть при любом разбиение множество состояний системы X диагностика состояния системы возможна

при фиксированных аппаратно-временных затратах. Для решения поставленной задачи оперативной диагностики состояния технической системы использовались нейронные сети с тремя слоями, так как такие сети способны разграничивать области любой сложности. На рис.3 представлены различные архитектуры нейронных сетей в зависимости от сложности задачи разбиения множества состояний на классы.

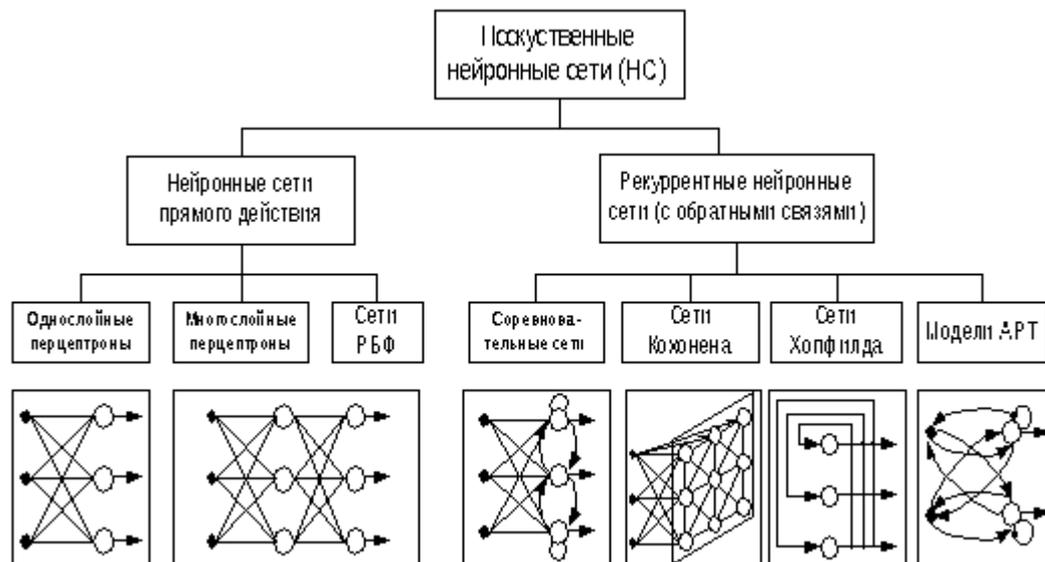


Рис.3 – Применение нейронных сетей с различной конфигурацией [3]

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

$$V_{ij} = A_{i0} - Z_{ij}$$

где $ij = 1, 2, \dots, k_1$, k_1 – количество разграничивающих плоскостей первого слоя.

В случае невыпуклых областей используются нейроны второго скрытого слоя C_{i_2} , $i_2 = 1, 2, \dots, k_2$, где 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

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

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

$F_a(x) = 1$ при $x > 0$, $F_a(x) = -1$ при $x \leq 0$;

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

A_{i_0} – нейроны входного слоя

Логические выражения задаются для каждого 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}

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

$W_{2,i_2,i_1} = 0$, 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:

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

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

\max_{i_0} – максимальное значение параметра

\min_{i_0} – минимальное значение параметра

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

– третий слой $W_{3,i_3,k_2+1} = -\sum_{j=1}^{k_2} W_{3,i_3,j} - 0,5$, $i_3 = 1, 2, \dots, k_3$

Представленный метод нейросетевой интерпретации правил функционирования сложной технической системы позволяет эффективно в режиме реального времени осуществить диагностику состояния системы.

Выводы

1. Для решения задачи оперативной диагностики состояния сложной технической системы, классификации типов возникающих ситуаций, обнаружения неисправностей, эффективным является применение нейропарадигмы в виде многослойной нейронной сети, обучаемой методом обратного распространения ошибки

2. Основой для применения предложенного метода является положение о разбиении множества состояний системы на конечное подмножество обучаемых классов при заданных ограничениях на аппаратно-временные затраты.

Библиографический список

1. Васенков Д.В. Методы обучения искусственных нейронных сетей // Компьютерные инструменты в образовании. - 2007. - №1. – С. 20-29.
2. Вежнев А. Популярныe нейросетевые архитектуры // Компьютерная Графика и Мультимедиа Сетевой журнал. – 2004. - №2.
3. Головкин, В.А. Нейронные сети: обучение, организация и применение. – М.: ИПРЖР, 2001 – 256с.

4. Дубровин В.И., Субботин С.А. Алгоритм ускоренного обучения персептронов // Сборник трудов IV всероссийской научно-технической конференции "Нейроинформатика-2002" – М.: МИФИ, 2002 – 7с.
5. Клюкин В.И., Николаенков Ю.К. Нейросетевые структуры и технологии. Часть 1. Электрические и математические модели нейронов. НС прямого распространения Учебное пособие. – Воронеж, Издательско-полиграфический центр ВГУ, 2008 – 63с.
6. Коровин Я.С. Методика объяснений нейросетевых решений // Материалы 4 ежегодной международной научной молодежной конференции ЮНЦ РАН, Изд-во ЮНЦ РАН, 2008 – с.152-155.
7. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – М., Горячая линия-Телеком, 2002 – 382с.
8. Потапов В.В. Формальные нейроны как элементы систем автоматического управления и вычислительной техники – Энциклопедия измерений, контроля и автоматизации. – М.: Энергия, 1970, №14 – с.41-44.
9. Carpenter G.A. Absolutely stable learning of recognition codes by a self-organizing neural network. – 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. – Lect. Notes Biomath, 1982, P. 267-285.
11. Hopfield J., Tank D. Neural computation of decisions in optimisation problem // Biological Cybernetics, 1985, Vol 52. – P. 141-142.
12. Marakas G. M. Decision support systems in the twenty-first century // Marakas G. MM Upper Saddle River, N.J.: Prentice Hall, 1999.
13. Patrick. P. Minimisation methods for training feedforward Neural Networks. – NEURAL NETWORKS, 1994, Vol 7, Number 1, P. 1-11.

14. Personaz L. A simple selectionist learning rule for neural networks. – 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. – 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 // Americas Conference on Information Systems, Long Beach, California, 2000

Оригинальность 75%