

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.032.26

ИСПОЛЬЗОВАНИЕ НЕЙРОННОЙ СЕТИ ПЕРСЕПТРОНА ДЛЯ ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ПРОМЫШЛЕННОЙ СИСТЕМЫ

С. Аббасипаям, Н.В. Мокрова

Московский государственный строительный университет, г. Москва, Россия

Сокращение выбросов в системах электрогенераторов напрямую коррелирует с количеством топлива, которое они используют. В данной статье выполнено моделирование газовой турбины промышленной системы электроснабжения. Энергия, необходимая турбинам, в значительной степени обеспечивается за счет ископаемых видов топлива. Точное понимание динамики газовой турбины приводит к лучшему контролю и, следовательно, к снижению расхода топлива, что в конечном итоге положительно влияет на окружающую среду. Использование алгоритмов искусственного интеллекта предложено в качестве мощного инструмента для моделирования и идентификации промышленных систем со сложной нелинейной динамикой, таких как газовые турбины. С использованием исходных параметров входа и выхода газовой турбины, построена модель искусственной нейронной сети перцептрона. Перед основным процессом идентификации алгоритма, с целью улучшения функциональности сети, данные предварительно обработаны. Нейросетевая программа перцептрона включает в себя различные обучающие функции, различное количество нейронов, а также типы активации для скрытых слоев и выходного слоя сети. Результаты реализации алгоритма приведены с использованием различных линейных, радиальных и симметричных передаточных функций в среднем и выходном слоях. Результаты показывают, что функция обучения (trainlm) имеет лучший сигнал выхода, чем стандартная (средняя квадратическая ошибка), по сравнению с любыми другими функциями обучения. Искусственная нейронная сеть перцептрона может использоваться в качестве метода для моделирования и идентификации сложных систем с нелинейной динамикой.

Ключевые слова: *газовая турбина, идентификация системы, нейронная сеть перцептрона, оценка параметров, искусственное нейронное моделирование.*

USING PERSEPTRON NEURAL NETWORK TO DETERMINE THE PARAMETERS OF THE INDUSTRIAL SYSTEM

S. Abbasipayam, N.V. Mokrova

Moscow State University of Civil Engineering, Moscow, Russia

The reduction in emissions in power generator systems is directly correlated with the amount of fuel they use. In this article, the simulation of a gas turbine of an industrial power supply system is performed. The energy required by the turbines is largely provided by fossil fuels. An accurate understanding of gas turbine dynamics leads to better control and therefore lower fuel consumption, which ultimately has a positive impact on the environment. Use of artificial intelligence algorithms is proposed as a powerful tool for modeling and identifying industrial systems with complex nonlinear dynamics, such as gas turbines. Using the initial parameters of the gas turbine input and output, a model of the artificial neural network of the perceptron is constructed. Before the main algorithm identification process, in order to improve the network functionality, the data is pre-processed. The perceptron neural network program includes various training functions, a different number of neurons, and activation types for hidden layers and the output layer of the network. The results of the algorithm implementation are presented using various linear, radial, and symmetric transfer functions in the middle and output layers.

The results show that the training function Levenberg-Marquardt optimization has a better output signal than the standard (mse), compared to any other training functions. The artificial neural network of the perceptron can be used as a method for modeling and identifying complex systems.

Keywords: *gas turbine, system identification, perceptron neural network, parameter estimation, artificial neural modeling.*

Введение

Сегодня растущая потребность в электроэнергии вынуждает страны создавать современные электростанции разной мощности, на которых широко используются газовые турбины.

Большинство электростанций сегодня строятся вокруг городов и жилых районов, поэтому проблемы шумового и теплового загрязнения должны быть учтены. Предоставление решений по проектированию и моделированию, направленных на качественное управление промышленными системами для снижения выбросов газовых турбин, является

одной из основных задач производителей этого типа промышленного оборудования.

Более точное управление приводит к снижению расхода топлива для газовых турбин, что может быть способом снижения загрязнения окружающей среды. Энергия, необходимая для газовых турбин, в основном вырабатывается из ископаемого топлива, и они являются частью оборудования, которое в свою очередь берет энергию из ископаемого топлива. Хотя технологии контроля загрязняющих веществ в оборудовании турбин развиваются, но наиболее важный фактор снижения загрязнения окружающей среды можно

найти в снижении потребления ископаемого топлива, что, в свою очередь, достигается изменением динамики и разработкой систем контроля газотурбинной установки. Следовательно, достижение целей управления требует глубокого знания свойств модели системы. Любые ограничения возможностей системы управления приводят к снижению производительности, увеличению загрязнения окружающей среды и высокой стоимости энергоресурсов.

Сложные динамические и термодинамические связи технологической системы газовой турбины, а также её сложная структура, приводят к необходимости аналитического моделирования, что подтверждается исследованиями газовых турбин [1]. Подобные модели имеют множество упрощенных предположений.

Технологическая система, имеющая в своем составе газотурбинную установку, представляет собой многомерный многосвязный нелинейный объект управления со сложной динамикой. Получить все определяющие уравнения и отношения между переменными в системе практически невозможно, и аналитическое моделирование ведут с большим количеством упрощающих допущений, несмотря на его высокую заявленную точность [2].

Одно из важных допущений – линейность, с установкой математической связи между входными и выходными данными. Для реализации функций управления газотурбинной установкой в полной мере при аналитическом моделировании газовой турбины необходимо получить математическую зависимость между всеми переменными системы, причем сами параметры должны быть определены.

Методы моделирования газотурбинных систем

Процедура идентификации системы состоит из двух этапов. На первом этапе идентификация системы проводится с использованием линейной модели [2]. Если моделирование с помощью линейных моделей не отвечает требованиям адекватности, то можно использовать нелинейные модели, например, нейронные сети [3–4].

Идентификация математической модели реальной системы – есть создание модели для динамических систем, наблюдаемых данных. Процесс идентификации газотурбинной системы включает описание системы как объекта управления, предварительную обработку данных, определение структуры системы, проведение испытаний и сбор модельных данных, оценку параметров и оценку адекватности модели.

На этапе предварительной обработки данных шум удаляется с использованием фильтра нижних частот, затем данные нормализуются. Для обработки данных, полученных на конкретной газотурбинной установке, использован алгоритм, предложенный в [5], он позволяет определить время выборки для идентификации структуры. Математическая модель газовой турбины состоит из алгебраических уравнений, учитывающих время задержки, а затем вводятся дополнительные функции модели [6–7]. Модели амплитуды частот были предложены Хантом в [8]. Статические нелинейные модели с постоянными значениями постоянного тока или линейными приближениями, которые сильно зависят от выбора рабочей точки, представлены с помощью модели Хаммершайна-Винера [9]. В работе [10] подробно рассмотрены различные аспекты распознавания систем.

Модель нейросети перцептрон

Искусственные нейронные сети являются частью интеллектуальных систем, основанных на моделях, которые передают знания или закон о данных в структуру сети путем обработки этих данных [11]. Нейронные сети могут оценивать широкий спектр моделей без четкой связи между зависимыми и независимыми переменными реального объекта управления. Методы определения коэффициентов нейронной сети основаны на классических методах обратного распространения, одним из наиболее популярных из которых является метод обратного распространения Левенберга-Марквардта [12].

Рассмотрим структуру сети перцептрона на рис. 1 [13].

Сеть перцептрон состоит из слоя с s нейронами и имеет R входов. Это базовая модель нейронных сетей, которые обладают способностью узнавать, идентифицировать и генерировать паттерны.




Рис. 1. Общая структура нейронной сети перцептрона

Вычислительные операции выполняются на нейронах, структура которых показана на рис. 2 [13–14].




Рис. 2. Нейронная структура с R входами и смещением

Искусственный нейрон из блока предварительной обработки, состоит из ретрансформатора и функции активации с несколькими входами и одним выходом. Один или несколько нейронов вместе образуют слой сети.

На рис. 1, элементы входного вектора p применяются ко всем нейронам, и после умножения вектора весов путем добавления смещения к передаточной функции получается выходной сигнал. Выход сети – вектор. В однослойной сети матрица весов w имеет размерность $s \times R$.

В формуле (1) n – передаточная функция с учётом смещения (b), входное значение p_i умножается на величину веса. Затем значение n входит в передаточную функцию f и присваивается значению a , которое является окончательным выходом нейрона (2).

$$n = w_{1,1} p_1 + w_{1,2} p_2 + \dots + w_{1,R} p_R + b \quad (1)$$

$$a = f(w_{1,1} p_1 + w_{1,2} p_2 + \dots + w_{1,R} p_R + b) = f(n) \quad (2)$$

Обычно одного нейрона недостаточно для решения сложных задач с несколькими входами, поэтому необходимо использовать нейронные сети, состоящие из нескольких нейронов и нескольких слоев.

В многослойной нейронной сети персептрона каждый слой имеет свою собственную весовую матрицу, векторы смещения и выходные данные, а выходные данные каждого слоя используются в качестве входных данных следующего уровня. Большинство нейронных сетей используют 2 и 3 слоя, сети с 4-мя или более слоями редко используются [14–15].

При идентификации системы нейроны выходного слоя обычно имеют линейную функцию активации. Обучение сети стремится минимизировать ошибку между выходом системы и выходом нейронной сети. Оценка параметров производится такими методами, как обратное распространение ошибок или Левенберг-Марквардт.

В статье модель искусственной нейронной сети с двухслойной структурой персептрона предназначена для определения основных параметров газовой турбины. Структура искус-

ственной нейронной сети обеспечивает гибкость её применения в зависимости от различных факторов, таких как количество нейронов, тип передаточных функций или тип алгоритма обучения.

Реализация алгоритма

В этом разделе представлены результаты идентификации турбинной системы с использованием системы персептрона.

Из всей таблицы экспериментальных данных случайным образом выбраны около 70 % данных, которые используются для обучения сети, 15 % – как данные испытаний, а остальные 15 % – как данные проверки.

Согласно анализу объекта управления, входные данные включают поток топлива и воздуха, температуру и давление окружающей среды.

Выходные векторы включают мощность турбины и температуру на выходе выхлопа. В скрытом слое задана нелинейная передаточная функция, а в выходном слое – линейная функция.

На рис. 3 показан оптимальный процесс управления обученной сети на основе критерия производительности – средней наименьшей ошибки для параметра мощности турбины, а на рис. 4 для параметра выходной температуры турбины.

Как видно, в равных условиях с числом итераций 100 по параметру мощность турбины сеть персептрона показывает лучшую производительность, чем по выходной температуре турбины.

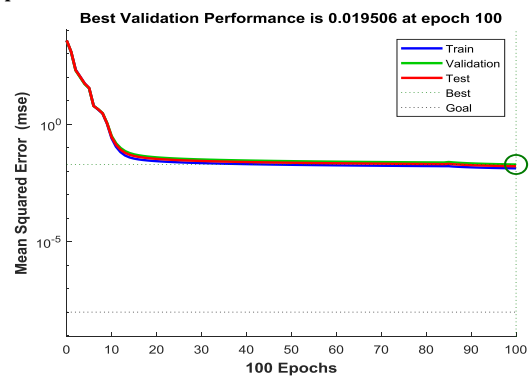


Рис. 3. Процесс управления по мощности турбины

Анализ процессов управления (рис. 3, 4) позволяет сделать вывод о возможности уменьшения значения ошибок. Ошибки обучения и валидации могут быть уменьшены вплоть до некоторого порогового значения, когда переобучения не происходит и ошибка проверки не увеличивается.

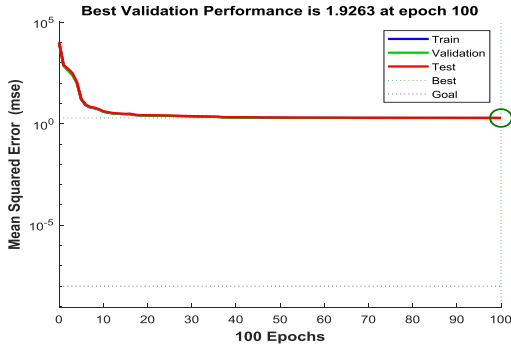


Рис. 4. Процесс управления выходной температурой турбины

Каждый из параметров нейронной сети может быть выбран в качестве точки остановки для реализации алгоритма. Для лучшей демонстрации оптимальной производительности нейронной сети, можно использовать условия остановки проверки данных [12–15]. Это означает, что максимальное количество раз, когда происходит рассогласование данных валидации, выбирается количество раз, разрешенных или не принятых сетью, которое, достигнув этого числа, станет лучшей точкой для обучения нейронной сети.

Тренировка прекращается при возникновении любого из этих состояний:

- достигается максимальное количество эпох (повторений);
- максимальное количество времени превышено;
- производительность сводится к минимуму до достижения цели;
- μ превышает максимум μ ;
- производительность валидации увеличилась более чем в два раза с момента ее последнего снижения (при использовании валидации).

В нейронной сети перцептрона нелинейные функции алгоритма определяются методом Левенберг-Марквардт, основанным на идее доверительного региона. В большинстве случаев этот метод очень быстро сходится.

trainlm может обучать любую сеть, если ее весовые, входные и передаточные функции имеют производные функции.

Векторы проверки используются для преждевременного прекращения обучения, если производительность сети на векторах проверки не улучшается или остается неизменной для периодов max_fail подряд.

Каждая переменная регулируется согласно Левенбергу-Марквардту (3),

$$\begin{aligned} j^T j &= jx * jx \\ j^T e &= jx * E \\ dx &= -(j^T j + I * \mu) \setminus j^T e \end{aligned} \quad (3)$$

где e – вектор сетевых ошибок, E – все ошибки, а I – единичная матрица тогда $j^T j$ – гессианская, а $j^T e$ – градиентная матрица, j – матрица Якоби, содержащая первые производные сетевых ошибок по весам и смещениям. Первоначальное значение $\mu = 0.001$.

μ уменьшается после каждого успешного шага и увеличивается только тогда, когда предварительный шаг может увеличить функцию производительности.

На рис. 5 показана регрессия между выходом алгоритма сети перцептрона и параметром выходной мощности турбины.

Значение R указывает на связь между выходом сети и выходом цели. Числовое значение R для наборов данных обучения, тестирования и проверки близко к 1, что указывает на хорошее соответствие для всего набора данных.

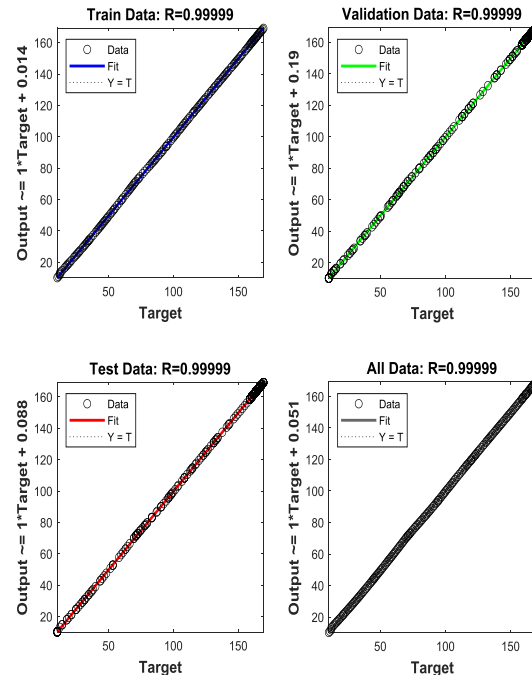


Рис. 5. График регрессии для набора данных мощности турбины

На рис. 6 показана регрессия между выходом алгоритма сети перцептрона и параметром температуры выхлопа турбины.

Сравнение результатов между двумя параметрами мощности и выходной температурой показывает, что степень адаптации для параметра мощности турбины выше, чем температура. Следовательно, точность моделирования и контроля температуры турбины имеет большее значение. Алгоритм сети перцептрона тестируется с различным количеством нейронов и различными функциями обучения сети, а

также с функциями активации в выходном и скрытом слоях.

Среди обучающих функций три тренировочные функции `traindgd`, `trainbfg` и `traingda`, самые слабые показатели и функции обучения `traincgb`, `traingcg` и `trainrp`, с умеренной производительностью и функции обучения `trainlm` с функциями передачи `tansig` в скрытом слое и `purelin` в выходном слое показали лучшую производительность.




Рис. 6. График регрессии для набора данных выходной температуры турбины

Таблица 1

Результаты реализации алгоритма нейронной сети перцептрона с различными обучающими функциями и функциями активации с различным числом нейронов для параметра мощности турбины

Тренировочная функция	Функция преобразования скрытого слоя	Функция преобразования выходного слоя	Количество нейронов	Средняя квадратическая ошибка
trainlm	tansig	purelin	2	1.1585e-01
			3	7.4912e-02
			4	4.8866e-02
			5	1.3825e-02

Представлены результаты реализации алгоритма для обучающей функции `trainlm` с различным числом нейронов для параметра мощности турбины в табл. 1 и для параметра выходной температуры турбины в табл. 2. Эти результаты основаны на критерии среднеквадратичной ошибки.

Сравнение результатов реализации алгоритма по параметрам мощности и выходной

температурой показывает, что для выходного температурного параметра требуется большее количество нейронов для выполнения процесса идентификации.

Как можно видеть, сравнивая результаты, обучающая функция, основанная на методе распространения ошибок, показывает лучшую производительность, чем другие обучающие функции.

Алгоритм нейронной сети перцептрона кодируется вместе с обучающими функциями, используемыми в программном обеспечении MATLAB.

Таблица 2

Результаты реализации алгоритма нейронной сети перцептрона с различными обучающими функциями и функциями активации с различным числом нейронов для параметра выходной температуры турбины

Тренировочная функция	Функция преобразования скрытого слоя	Функция преобразования выходного слоя	Количество нейронов	Средняя квадратическая ошибка
trainlm	tansig	purelin	2	2.6314e+00
			5	1.6645e+00
			8	9.8020e-01
			12	6.8048e-01

Заключение

В статье разработан алгоритм идентификации параметров газотурбинной установки на основе комбинации различных обучающих функций, количества различных нейронов и передаточных функций для искусственной нейронной сети перцептрона. Каждый запуск сетевого алгоритма перцептрона приводит только к одному выходу технологической системы.

Следовательно, для каждого выхода турбинной системы сеть перцептрона рассматривается как система с несколькими входами и одним выходом. Это необходимо для предотвращения чрезмерной сложности алгоритма и снижения производительности сети.

Результаты показывают, что функция обучения (`trainlm`) имеет лучший сигнал выхода, чем стандартная (средняя квадратическая ошибка), по сравнению с любыми другими функциями обучения. Можно сделать вывод, что искусственная нейронная сеть перцептрона может использоваться в качестве надежного метода для моделирования и идентификации сложных систем с нелинейной динамикой.

Список литературы

1. Ahmadi, S., Karari, M., Identification of Nonlinear Systems, Amirkabir University of Technology Press, Collection of articles, 2016.
2. W.A.Docter, C.Georgakis Identification of reduced order Average linear models from nonlinear dynamic simulations, American Control Conference, vol. 5, pp. 3047-3052, June 1997.
3. K. Glover, Perturbation Signals for System Identification, Prentice Hall: New York, pp.2-5. 1993.
4. KJ. Hunt, D. Sarbaro, R. Zbikowski and PJ. Gawthrop, Neural Networks for Control Systems-A Survey, Automatica, vol. 28, pp. 1083- 1112, November 1992.
5. S.A. Billings and L.A. Aguire, Effects of the Sampling Time on the Dynamics and Identification of Nonlinear Model",529 International JOW11al of Bifurcation and Chaos, vol. 5, pp. 1541-1556, December 1995.
6. W. I.Rowen, Simplified Mathematical Representation of Heavy-Duty Gas Turbines, ASME Journal of Engineering for Power, 1983.
7. W.I.Rowen, Simplified Mathematical Representation Of Single Shaft Gas Turbines in Mechanical Drive Service, The International Congress and Exposition, 1992.
8. L.N.Hannet, Afzal Khan, Combustion Turbine Dynamic Model Validation from Tests, IEEE Transaction on Power System, Vol.8, № 1, 1993.
9. Jurado F, Cano A, Use of ARX algorithms for modelling microturbines on the distribution feede", IEE Proc Generat Transm Distribut. 2004.
10. S. k. Yee, J. V. Milanovic, F. M. Hughes, Overview and comparartive analysis of gas turbine, IEEE Transactions of power systems, Vol.23, № 1, February 2008.
11. Y. Zhu, Multivariable system identification for process control, Elsevier, 2001.
12. Hagan, M. T., and Menhaj, M. B. Training feedforward networks with the Marquardt algorithm. IEEE transactions on Neural Networks 5, № 6 (1994): 989-993.
13. Ke-Lin Du, M. N. S. Swamy Neural Networks and Statistical Learning. Springer Science & Business Media; ISBN: 978-1447155706, 2014 edition.
14. Demuth, H.B., Beale, M.H., De Jess, O. and Hagan, M.T. Neural network design, 2014.
15. Dreyfus, G. Neural networks: methodology and applications. Springer Science & Business Media, 2005.

© С. Аббасипаям, Н.В. Мокрова

Ссылка для цитирования:

С. Аббасипаям, Н.В. Мокрова. Использование нейронной сети персептрона для определения параметров промышленной системы // Инженерно-строительный вестник Прикаспия : научно-технический журнал / Астраханский государственный архитектурно-строительный университет. Астрахань : ГАОУ АО ВО «АГАСУ», 2020. № 4 (34). С. 106–111.

УДК 004.91

**МОДЕЛЬ КОНТРОЛЯ РАСПРЕДЕЛЕНИЯ И ОСВОЕНИЯ КОМПЕТЕНЦИЙ
ПО ДИСЦИПЛИНАМ УЧЕБНОГО ПЛАНА**

И.В. Аксютина, В.М. Зарипова, И.Ю. Петрова

Астраханский государственный архитектурно-строительный университет, г. Астрахань, Россия

В статье обоснована необходимость разработки программного обеспечения для контроля распределения компетенций и индикаторов их достижения по дисциплинам учебного плана. Это программное обеспечение и база данных компетенций, индикаторов и результатов обучения должны быть интегрированы с базой учебных планов в 1С Университет. В статье определены правила проверки распределения компетенций и индикаторов по дисциплинам учебного плана. Множество дисциплин учебного плана и множество компетенций и индикаторов представлено в виде двудольного графа, что позволяет алгоритмизировать процесс проверки согласованности распределения компетенций и индикаторов по дисциплинам. Разрабатываемое программное обеспечение позволит осуществлять контроль полноты и качества распределения результатов освоения в каждой ОПОП ВО, реализуемой в вузе, в соответствии с учебным планом.

Ключевые слова: ФГОС ВО 3++, компетенция, учебный план, дисциплина, контроль на согласованность, анализ качества.

**MODEL OF CONTROL OF INTRODUCTION AND DISTRIBUTION OF COMPETENCIES
IN DISCIPLINES OF THE UNIVERSITY CURRICULUM**

I.V. Aksyutina, V.M. Zaripova, I.Yu. Petrova

State University of Architecture and Civil Engineering, Astrakhan, Russia

The article substantiates the need to develop software to control the distribution of competencies and indicators of their achievement in the disciplines of the curriculum. This software and the database of competencies, indicators and learning outcomes should be integrated with the information system maintaining the curriculum base (like 1C University). The article defines the rules for checking the distribution of competencies and indicators between disciplines of the curriculum. A set of disciplines and set of competencies and indicators are presented in the form of a bipartite graph, which allows to algorithmize the process of checking the consistency of the distribution of competencies and indicators between disciplines. The developed software will make it possible to control the completeness and quality of the distribution results in each curricula, implemented at the university.

Key words: GEF HE 3 ++, competence, curriculum, discipline, control for consistency, quality analysis.