

УДК 004.896

**РАЗРАБОТКА КОНФИГУРАТОРА НЕЙРО-НЕЧЁТКОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ
КОЭФФИЦИЕНТА ЗАГРУЗКИ ОБОРУДОВАНИЯ**

С.А. Ильина

Научный руководитель: доцент, к.ф.-м.н. М.Е. Семенов

Национальный исследовательский Томский политехнический университет,

Россия, г. Томск, пр. Ленина, 30, 634050

E-mail: sai8@tpu.ru

**DEVELOPMENT OF A CONFIGURATOR OF A NEURAL-FUZZY NETWORK FOR PREDICTING
THE LOAD FACTOR OF EQUIPMENT**

S.A. Ilina

Scientific Supervisor: Assoc. Prof., PhD M. E. Semenov

Tomsk Polytechnic University, Russia, Tomsk, Lenin ave., 30, 634050

E-mail: sai8@tpu.ru

***Abstract.** In this article, the creation of network configurator based on adaptive neuro-fuzzy inference system (ANFIS) has been described. The proposed network used to predict the load factor of production equipment based on data from sensors (SCADA), operational reports and simulation model. The load factor of production equipment has been predicted with error less than 5%.*

Введение. В условиях производства на оборудование влияет множество внешних факторов, при этом оборудование не всегда используется равномерно, что приводит к постепенному ухудшению технического состояния и может привести к неисправности или даже поломке. Для диагностики и прогнозирования потенциальных неисправностей оборудования применяются различные методы и модели проактивной поддержки принятия решений. Предложенные решения можно разделить на три класса: а) подходы, основанные на физических моделях (physical-based methods, PhM), б) использовании формализованных знаний (knowledge-based methods, KBM), в) анализе данных (data-driven methods, DDM) [1, 2]. В данный момент, на производствах часто применяют экспертный подход, при котором не всегда удаётся учесть фактические режимы работы и, как следствие, реальную загрузку оборудования. В этой работе мы предлагаем использовать нечёткие нейронные сети для организации планово-предупредительного ремонта, чтобы уточнить фактическую загрузку оборудования и учесть динамические режимы его работы. Данная интеллектуальная система позволит реализовать прогнозирование остаточного ресурса на основе анализа данных, но с учётом правил, применяющихся при экспертном подходе диагностики технического состояния оборудования.

Структура сети и алгоритм. Разработанная нейро-нечёткая сеть (ННС) имеет нечёткую и линейную части. Некоторые параметры сети настраиваются пользователем на основании его данных. Нечёткая часть представлена ANFIS моделью, состоящей из пяти слоёв (рис. 1, слева).




Рис. 1. Общая схема нейро-нечёткой сети на основе ANFIS модели

Слой 1 получает входные параметры x , y , каждый из которых представлен отдельным нейроном и вводит их в модель ANFIS. Этот слой считается входом нечёткой системы. Выход *Слоя 1* становится входом *Слоя 2*, несущего предыдущие значения функций принадлежности Π , которые распределяются на основе входных значений. Узлы *Слоя 2* определяют нечёткие правила и передают их на *Слой 3* сети с соответствующей степенью активности w_1 , w_2 . Затем, *Слой 3* нормализует степени активности правил, \bar{w}_1 , \bar{w}_2 . *Слой 4* (слой консеквентов) принимает узлы и функции и представляет модель первого порядка на основе производных параметров, отправляя их на выходной *Слой 5* (сумматор Σ) [3]. Заметим, что на этапе слоя консеквентов (*Слой 4*) используются следствия Такаги-Сугено-Канга. Линейная часть (рис. 1, справа) содержит *Входной слой* с одним нейроном, несколько *Скрытых слоёв* с произвольным количеством нейронов на каждом из них, и *Выходным слоём* с одним нейроном. Входной слой принимает выход с сумматора на *Слое 5* и вводит данные на первый *Скрытый слой*. Каждый скрытый слой применяет различные преобразования к входным данным и передаёт результаты на следующий. Выходной слой принимает выход с последнего *Скрытого слоя* и преобразовывает данные в одномерный вектор.

В линейной части настраиваемыми параметрами является количество скрытых слоёв и нейронов на них, а также тип функций активации (сигмоидальная, ReLU или GeLU) для каждого внутреннего слоя. Также пользователь может задать количество эпох обучения.

Для обучения нечёткой и линейно частей разработанной ННС в данной работе используется алгоритм обратного распространения ошибки. В алгоритме обратного распространения различают два прохода, выполняемых в процессе вычислений: первый проход называют прямым (forward pass), второй – обратным (back pass). При прямом проходе (forward pass) синаптические веса остаются неизменными во всей сети, но последовательно вычисляются функциональные сигналы. Реализован алгоритм обратного распространения с использованием среднеквадратичной ошибки для настройки параметров. В качестве оптимизатора используется устойчивый алгоритм обратного распространения (реализация Rprop из библиотеки PyTorch).

Вычислительные эксперименты и их обсуждение. Для демонстрации возможностей выбранной модели проведён подбор параметров, обучена и протестирована модель на наборе данных, состоящем из векторов взвешенной суммы: а) данных с системы датчиков SCADA, б) данных оперативных отчётов, и в) данных имитационной модели, а также из вектора соответствующих коэффициентов неравномерности загрузки. Для оценки качества результатов тестирования мы использовали среднеквадратичную ошибку (MSE) и ошибку обучения (PE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2, PE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{\hat{Y}_i} \right|$$

где n – величина выборки, \hat{Y}_i – спрогнозированная величина, Y_i – действительное значение.

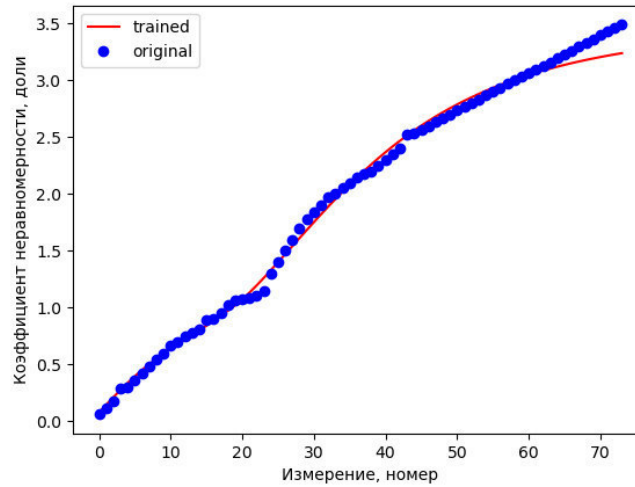


Рис. 2. Сравнительный график спрогнозированных при тестировании значений с реальными данными:

$$MSE = 0,00581, PE = 3,9\%.$$

Заключение. В ходе вычислительного эксперимента мы продемонстрировали результаты обучения и тестирования разработанной нейро-нечёткой сети. Представленная ННС позволяет спрогнозировать коэффициент загрузки производственного оборудования с достаточной точностью (ошибка не более 5%). На основе полученного коэффициента можно статистически вычислить остаточный ресурс оборудования и спланировать график проведения предупредительных ремонтных работ, а также определить оптимальное количество и время закупки запасных частей, необходимых для ремонта. Всё это может помочь производствам ощутимо сократить свои эксплуатационные расходы.

СПИСОК ЛИТЕРАТУРЫ

1. Lei Y. Intelligent Fault Diagnosis and Remaining Useful Life Prediction of Rotating Machinery. – Butterworth-Heinemann, 2017. – 366 p.
2. Сай Ван Квонг. Модели и методы проактивной поддержки принятия решений при управлении техническим состоянием оборудования: Дис. канд. тех. наук / Волгоградский государственный технический университет – Волгоград, 2020. – 152 с.
3. Najafi B., Ardabili S.F. Application of ANFIS, ANN, and logistic methods in estimating biogas production from spent mushroom compost // Resources, Conservation and Recycling. – 2018. – Vol. 133. – P. 169-178.
4. Леоненков А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH. —СПб.: БХВ Петербург, 2005. – 736 с.
5. Ильина С.А., Семенов М.Е. Разработка конфигуратора прогноза планово-предупредительных ремонтов с применением нейро-нечётких систем // Материалы докладов XVII Международной научно-практической конференции «Электронные средства и системы управления». – 2021. - ч. 2. - С. 308-310.