

УДК 621.313.333.2

Г.В. Суханкин, Н.П. Воробьев

Модель остаточного ресурса технического объекта на примере электродвигателя с помощью нейронечеткой системы

Рассматривается методика построения обучаемой нейронечеткой системы диагностики электродвигателей (ЭД). Результат работы такой системы – определение остаточного ресурса ЭД. Для построения и обучения такой системы использовались сигмоидные функции принадлежности, метод обратного распространения ошибки и др.

Ключевые слова: диагностика, нейронечеткая система, остаточный ресурс, электродвигатель.

В настоящее время диагностика такого технического объекта, как электродвигатель, является актуальной. Действительно, внезапный выход из строя любого типа ЭД часто приводит к остановке технологического процесса, что связано с недоотпуском разного рода продукции, а следовательно, снижением прибыли. При этом целесообразно определять не только текущее состояние ЭД, но и его остаточный ресурс. Актуальность определения остаточного ресурса связана как с применением относительно дешевых ЭД асинхронного типа, так и, например, с использованием высоковольтных тяговых электродвигателей. Первое связано с массовостью применения, второе – с высокой стоимостью изделий.

Основной сложностью при проектировании интеллектуальных диагностических систем являются не алгоритмы обработки данных в таких системах и не структура самих систем, а именно получение достоверных диагностических признаков и определение связей между ними. Важным также является и то, чтобы диагностическая система могла обучаться на основе сравнения результата на выходе системы с реальными данными объекта эксплуатации. Необученная диагностическая система не представляет практически никакой ценности. Обычно, но не обязательно, обучение производится по методу обратной ошибки (backpropagation) [1]. Для анализа входных данных и их взаимосвязи используется оценка энтропии на основе подсчета ячеек (box-counting) [2]. В качестве базового блока сети часто применяется пятиступенчатая схема по типу Сугено [3] с сигмоидными функциями принадлежности на входе. Все это позволяет реализовать рассматриваемую сеть в какой-либо программной среде в виде нейронечеткой системы вывода.

Модель вычисления остаточного ресурса представляет собой полином:

$$z = f(x_1, \dots, x_n) = Ax_1^k x_2^l \dots x_n^m + Bx_1^o x_2^p \dots x_n^q + \dots + Cx_1^r x_2^s \dots x_n^t,$$

где – x_1, \dots, x_n – диагностические параметры (ДП), A, B, \dots, C – коэффициенты, k, l, \dots, t – показатели степеней.

В одном из вариантов диагностической системы коэффициенты полинома настраиваются так, что все плохие диагностические параметры дают на выходе остаточный ресурс $z = 0$ (лет), а все лучшие – максимальный (например, 5 лет). При подаче на вход диагностической системы экспериментального значения ДП выдается некоторый остаточный ресурс конкретного диагностируемого объекта в виде четкой величины. Такая схема может быть реализована, например, с помощью нечеткой системы Сугено [3]. Применение нечеткости в данном случае обусловлено тем, что некоторые параметры состояния технического объекта можно выразить лишь в терминах «хороший», «плохой», «высокий», «низкий» и т.д.

Недостатком подобной диагностической системы является ее неадаптивность.

Более предпочтительным является вариант настраиваемой диагностической системы с обратной связью.

Суть работы такой системы заключается в настройке коэффициентов в соответствии с выборкой (некоторого количества) экспериментально исследуемых объектов. ДП измеряются в момент отказа объекта и вводятся в обучаемую диагностическую систему, в которой автоматически изменяются коэффициенты полинома. При подаче на вход диагностической системы экспериментального значения ДП выдается некоторый остаточный ресурс конкретного диагностируемого объекта в виде четкой величины. Обучение системы заключается в нахождении разности значений ее выхода и пара-

метров состояния реального исследуемого объекта. Если такая разница существует, то она изменяет соответствующие коэффициенты полинома модели. Для вышедшего из строя двигателя такое сравнение производится с нулем в компараторе, который в дальнейшем интегрируется в саму систему и реализуется программно. Входы системы диагностики подключаются в соответствии со значениями кросс-энтропии. Авторами статьи такая система реализована в виде нейронечеткой системы Сугено.

Входной вектор диагностических признаков описывается девятью ($l = 9$) диагностическими параметрами, приведенными на рис. 1. В общем виде входной вектор диагностических признаков:

$$\mathbf{x}(n) = \{x_1(n), x_2(n), \dots, x_l(n)\}, \quad n = 1, 2, \dots, P,$$

где P – выборка.

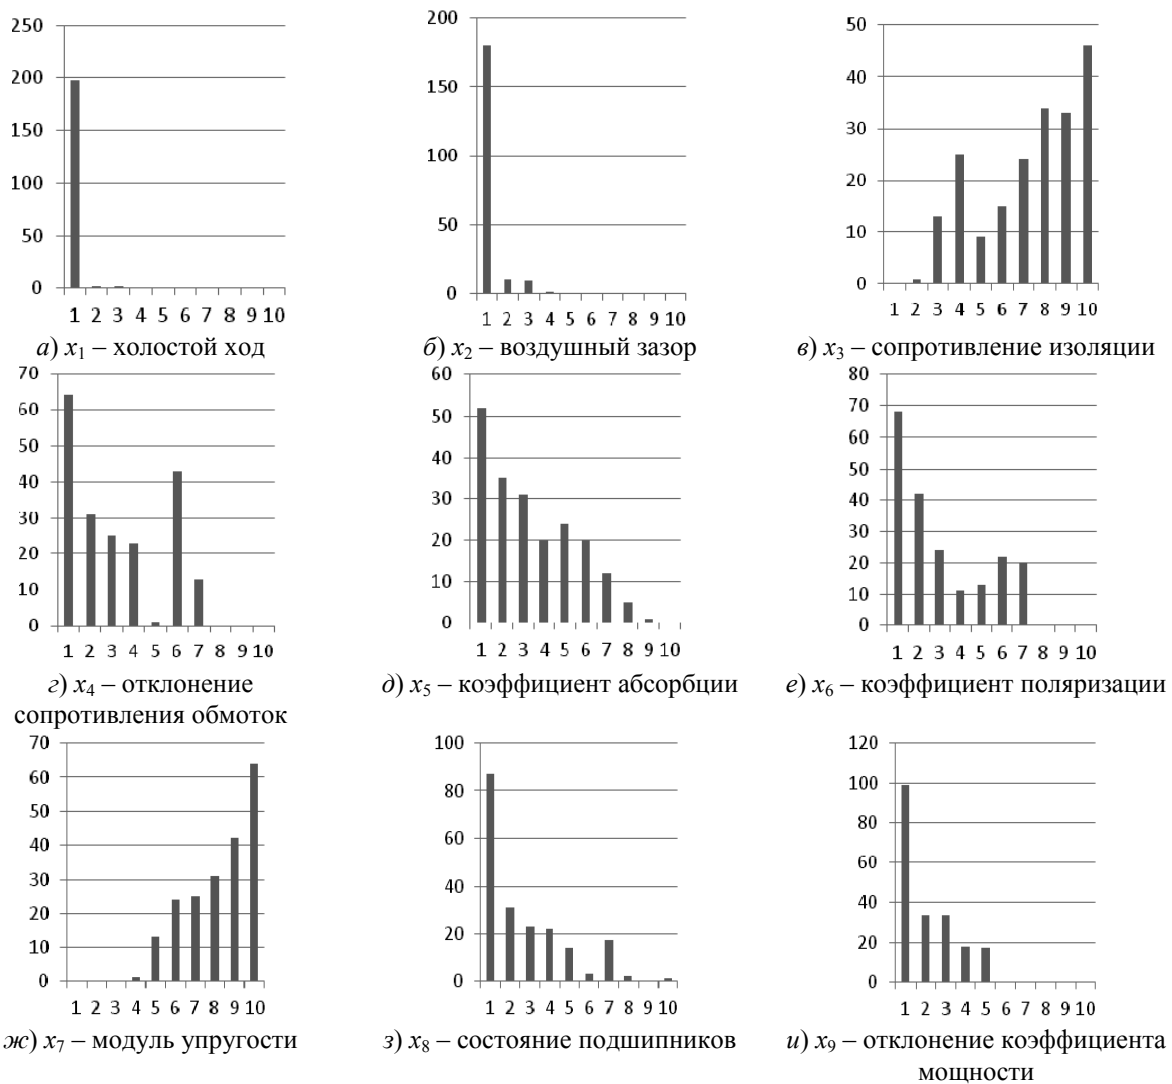
Нормирование входных параметров к диапазону $[0, 1]$ проводилось по соотношению:

$$x'_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}), \quad (1)$$

где x_{\max} – максимально возможное значение входного вектора, x_{\min} – минимально возможное значение входного вектора, x_i – текущее значение входного вектора, x'_i – нормализованное значение входного вектора.

Испытания электродвигателей проводились до отказа как по электрической части (выход из строя изоляции, как корпусной, так и межвитковой), так и механической (подшипники и др.)

Структура диагностической системы представлена на рис. 2 и представляет собой пирамиду с ориентированной вершиной вниз. На основание пирамиды подаются диагностические признаки.



Ось абсцисс – x'_i ; ось ординат P – выборка

Рис. 1. Совокупность диагностических параметров электродвигателя

Вершина пирамиды является выходом системы. Диагностическая система состоит из стандартных блоков, имеющих размерность векторного входа d , нумерация которых зависит от того, в

каком слое и узле находится блок. Слои, узлы и порядок подключения входных сигналов определяются по алгоритму [4]. Выход системы z является результатом работы вычисления остаточного ресурса ЭД. Реализация алгоритма [4] при $l = 9$, $d = 2$ (размерность векторного входа стандартного блока) при расчете взаимных кросс-энтропий диагностических признаков генерирует нейронечеткую сеть.

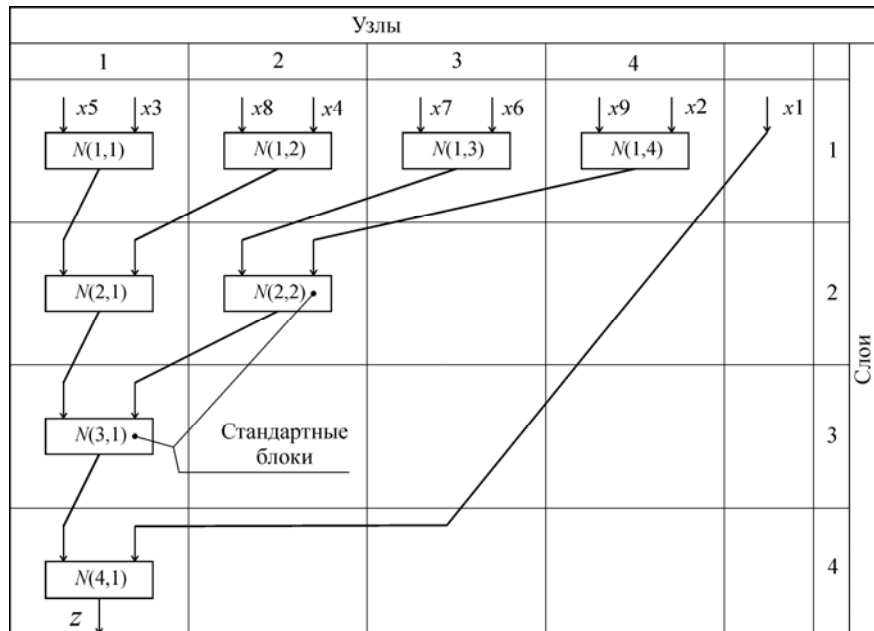


Рис. 2. Результат работы алгоритма: схема подключения диагностических признаков и генерация логической сети

Следует отметить, что по рис. 2 пары сигналов x_5 и x_3 , x_8 и x_4 , x_9 и x_2 , имеют наименьшие значения кросс-энтропий. Таблицы кросс-энтропий имеют громоздкий характер и в данной статье не приводятся.

В качестве стандартного блока выбрана нейронечеткая схема по типу Сугено.

1-й слой – слой функций принадлежности. Выходы нейронов этого слоя представляют собой функции принадлежности, представленные сигмоидной функцией

$$\mu_{ij}(x_i) = \frac{1}{1 + \frac{1}{e^{a_{ij}(x - c_{ij})}}},$$

где a_{ij} – коэффициент крутизны, c_{ij} – координата перехода через 0,5, $i, j = 1, 2$. Настраиваются в процессе обучения сети.

2-й слой – слой правил. Вычисление функций на выходе нейронов этого слоя проводится по 4 правилам:

$$r_1 = \mu_{11}(x_1) \wedge \mu_{21}(x_2); \quad r_2 = \mu_{12}(x_1) \wedge \mu_{22}(x_2); \quad r_3 = \mu_{12}(x_1) \wedge \mu_{21}(x_2); \quad r_4 = \mu_{11}(x_1) \wedge \mu_{22}(x_2).$$

3-й слой – здесь производится нормализация уровней истинности правил по формуле

$$\beta_i = \frac{r_i}{\sum_{i=1}^4 r_i}, \quad i=1, \dots, 4.$$

4-й слой. Количество узлов соответствует 2-му и 3-му слоям. Каждый узел этого слоя соединен со всеми выходами 3-го слоя, а также со всеми входами сети. На выходе этого слоя формируется диагностическая модель в виде полинома

$$y_i = \beta_i(b_{i0} + b_{i1}x_1 + b_{i2}x_2), \quad i = 1, \dots, 4,$$

где $b_{i0} \dots b_{i2}$ – настраиваемые в процессе обучения сети коэффициенты.

5-й слой. Суммирование результатов 4-го слоя осуществляется по соотношению


$$y = \sum_{i=1}^4 y_i.$$

Для правильной работы сети необходимо провести ее настройку, или обучение. Суть настройки сети сводится к регулировке коэффициентов a_{ij} , c_{ij} , b_{i0} , b_{i1} , b_{i2} . Среднеквадратичная ошибка сети рассчитывалась по формуле

$$E = \left[\sum_{j=1}^P (t_j - z_j)^2 \right] / P,$$

где t – требуемое значение выхода, z – истинное значение выхода последнего стандартного блока. При выборке $P = 100$, количестве циклов обучения (эпох), равном 30, абсолютная ошибка остаточного ресурса составила 50,8 ч, нормализованное значение ошибки составило $8,6 \cdot 10^{-4}$, среднеквадратичная ошибка составила $1,19 \cdot 10^{-5}$. Процесс обучения нейронечеткой сети иллюстрируется рис. 3.

Абсолютная ошибка
остаточного ресурса, ч



Система разработана в
Microsoft Excel и Visual
Basic for Applications.

Рис. 3. Оценка работы
диагностической системы
по определению остаточного
ресурса ЭД с помощью
вычисления абсолютного
значения ошибки
остаточного ресурса

Закключение. На основании полученных данных можно сделать следующие выводы.

1. Работоспособность разработанной диагностической системы по определению остаточного ресурса ЭД очевидна ввиду малых значений вышеприведенных ошибок (абсолютная, нормализованная, среднеквадратичная).
2. Правильный выбор конфигурации сети (количество стандартных блоков, разрядность, схема подключения, коэффициенты функций принадлежности в 1-м слое) позволяет сократить время обучения рассматриваемой сети по сравнению с полносвязанными сетями в 2,5–5 раз, что актуально в случае массового использования диагностируемых объектов, например асинхронных электродвигателей.
3. Соблюдение соотношения количества наблюдений (выборки), разрядности и настраиваемых коэффициентов сводит к минимуму возможность недопустимого переобучения сети, что связано с новыми периодами обучения.
4. Для повышения скорости обучения сети возможна ее модификация по алгоритмам, описанным в [4].

Литература

1. Введение в процедуру обратного распространения [Электронный ресурс]. – Режим доступа: <http://www.intuit.ru/departement/ds/neuronnets/4/5.html> – Загл. с экрана (дата обращения: 19.10.2012).
2. Ежов А.А. Нейрокомпьютинг и его применение в экономике и бизнесе / А.А. Ежов, С.А. Шумский. – М.: МИФИ, 1998. – 224 с.
3. Штовба С.Д. Проектирование нечетких систем средствами MatLab / С.Д. Штовба. – М.: Горячая линия–Телеком, 2007. – 288 с.
4. Безруков Н.С. Построение и моделирование адаптивной нейронечеткой системы в задаче медицинской диагностики / Н.С. Безруков, Е.Л. Еремин // Медицинская информатика. – 2005. – № 2(10). – С. 36–46 [Электронный ресурс]. – Режим доступа: <http://ics.khstu.ru/journal/articles/583>, свободный (дата обращения: 19.10.2012).

Суханкин Геннадий Владимирович

Канд. техн. наук, директор Информационно-издательского центра АлтГТУ им. И.И. Ползунова

Тел.: 8 (385-2) 29-07-44

Эл. почта: gen195@mail.ru

Воробьев Николай Павлович

Д-р техн. наук, доцент, профессор каф. «Электрификация производства и быта» АлтГТУ

Тел.: 8 (385-2) 36-71-29

Эл. почта: vnprol51p@ya.ru

Suhankin G.V., Vorobev N.P.

Model of residual life of a technical object as an example of the electric motor using neurofuzzy system

The technique of constructing learning neurofuzzy diagnostic systems electric motors. The result of such a system is a determination of residual life of the motor. For the construction and training of such a system we used sigmoid membership functions, the method of back-propagation errors, etc.

Keywords: diagnosis, neurofuzzy system, residual life, motor.