

Ю.П. КОНДРАТЕНКО, д-р техн. наук, проф. ЧГУ им. П.Могилы
(г. Николаев)

Е.В. ГОРДИЕНКО, магистр НУК им. адм. Макарова (г. Николаев)

НЕЙРОСЕТЕВОЙ ПОДХОД К РЕШЕНИЮ ЗАДАЧИ ИДЕНТИФИКАЦИИ НЕСТАЦИОНАРНЫХ ПАРАМЕТРОВ ТЕХНОЛОГИЧЕСКИХ ОБЪЕКТОВ

Рассмотрены существующие способы идентификации технологических объектов. Предложен нейросетевой подход к решению данной задачи и продемонстрированы результаты его применения на примере идентификации параметров типовых динамических звеньев. Обоснован выбор архитектуры и алгоритма обучения нейронной сети. Ил.: 4. Библиогр.: 14 назв.

Ключевые слова: идентификация технологического объекта, нейронная сеть, динамические звенья.

Постановка проблемы и анализ литературы. Современные технологические объекты часто подвержены внешним и внутренним возмущающим воздействиям, имеющим стохастический характер, что, в свою очередь, приводит к нестационарному характеру изменения их параметров [1]. Примером могут служить судовые электроэнергетические системы, являющиеся сложными динамическими объектами, в которых осуществляется автоматическое управление взаимосвязанными величинами: частотой, напряжением, потоками активных и реактивных мощностей синхронных генераторов [2, 3].

В связи с этим при проектировании систем автоматического управления одной из основных задач становится задача идентификации объектов такого класса [1]. Настоящая статья посвящена исследованию возможностей применения аппарата искусственных нейронных сетей (НС) при решении задач идентификации технологических объектов на примере идентификации нестационарных параметров типовых динамических звеньев. Среди главных недостатков существующих способов идентификации – большой объем расчетов. Применение аппарата НС позволяет заметно снизить объем вычислений, а, следовательно, и уменьшить временные затраты.

В настоящее время в задачах управления и, в частности, в задачах идентификации нейронные сети, как правило, находят свое применение в виде нейросетевых эмуляторов и предикторов [4 – 6]. Иными словами, НС используется как нейросетевая модель объекта управления (ОУ) либо как нейросетевая система, прогнозирующая дальнейшее поведение ОУ, основываясь на снятой с объекта выборке (вход/выход) [5].

Однако, помимо этого, на практике для эффективного управления часто необходимо определять изменившиеся под воздействием внешних либо внутренних факторов параметры ОУ [1]. Очень распространена задача

идентификации неизвестных параметров объекта при известной его структуре (система алгебраических либо дифференциальных уравнений). Такой объект в литературе имеет условное название белый ящик.

Существует множество методов решения такой задачи: аппроксимация ОУ через представление в виде типового звена, цепи апериодических звеньев, идентификация на базе разложения передаточной функции ОУ в ряды, метод наименьших квадратов и прочие [7]. Они имеют целью поиск функции, аппроксимирующей данный ОУ. Как уже было сказано выше, основным недостатком этих методов – большой объем вычислений и аналитических выкладок, что делает процедуру идентификации сложной, а иногда и громоздкой.

Задачу идентификации можно рассматривать как задачу аппроксимации многомерной функции, когда для входного воздействия необходимо получить значения динамических параметров ОУ. Для решения такого класса задач целесообразно использовать НС [8, 9].

Цель статьи – синтез искусственной нейронной сети для решения задач идентификации нестационарных параметров технологических объектов на примере типовых динамических звеньев: апериодических и колебательных.

Проектируемый нейросетевой идентификатор должен определять вектор коэффициентов C по нескольким последовательным значениям выходного и входного сигналов ОУ (рис. 1).




Рис. 1. Идентификация объекта управления

Решение задачи идентификации рассмотрим на примере идентификации коэффициентов усиления k , постоянных времени T и коэффициента демпфирования ξ типовых динамических звеньев: апериодического и колебательного с соответствующими передаточными функциями (ПФ):

$$W_I(p) = \frac{k(t)}{T(t)p+1}, \quad (1)$$

$$W_{II}(p) = \frac{k(t)}{T(t)^2 p^2 + 2\xi(t) \cdot p + 1}. \quad (2)$$

Идентификация параметров апериодического звена. В качестве искомых параметров для апериодического звена выбраны коэффициент усиления k и постоянная времени T .

Лучшей нейросетевой структурой для решения подобных задач является, как известно, многослойный персептрон (МП) [8, 10].

Проектируемая НС должна определять параметры k и T по нескольким последовательным значениям входов и выходов ОУ. Примем количество значений выхода равным 5, и это будут последние 5 значений выходного сигнала ОУ к моменту выхода переходного процесса (ПП) в установившийся режим с шагом Δt . На вход ОУ будем подавать единичный ступенчатый сигнал, тогда фактически проектируемый идентификатор будет выполнять расчет параметров ПФ ОУ по виду его ПП.

Формирование обучающей и тестовой выборок. Для обучения НС прежде всего необходимо создать обучающую выборку. С этой целью для каждого набора значений k и T из диапазонов $k = \overline{1, 40}$, $T = \overline{1, 40}$ построены ПП апериодического звена и определено время окончания ПП. При этом временем окончания ПП считается такой момент времени, после которого значение выходной величины отличается от установившегося значения не более, чем на 5%. В результате сформированы два массива: первый (массив входов НС) состоит из 1600 векторов длиной 6 (5 последних дискретных значений выходной величины и заданное значение выходной величины ОУ), второй (массив желаемых выходов) состоит из векторов, содержащих соответствующие значения параметров k и T .

Тестовая выборка создавалась аналогичным образом и содержит 6241 вектор.

Обучающая и тестовая выборки нормировались путем приведения значений векторов к нормальному закону распределения с нулевым средним и дисперсией, равной 1 [11]. Приведение выполнялось по формуле:

$$P_n = \frac{P - \bar{P}}{\sigma_P}, \quad (3)$$

где P_n – элемент нормированного вектора; P – элемент нормируемого вектора; $\bar{P}$ – среднее значение соответствующих элементов векторов обучающей выборки; σ_P – среднеквадратичное отклонение соответствующих элементов векторов обучающей выборки.

Определение алгоритма обучения. После формирования обучающей и тестовой выборок было проведено обучение сети. При этом важное значение

имеет явление переобучения сети. Это явление проявляется в том, что НС работает с минимальной погрешностью при подаче на ее вход векторов обучающей выборки, однако выдает неверный результат при подаче произвольного вектора. Это означает, что сеть заучила примеры, но не научилась решать задачу [8, 11].

Одним из методов снизить либо избежать эффекта переобучения является метод регуляризации [8]. Его суть заключается в минимизации комбинированного функционала качества обучения, который учитывает не только сумму квадратов ошибок обучения, но и квадраты весов [11].

В данном исследовании этот метод реализован в алгоритме Левенберга-Марквардта с регуляризацией по Байесу, который показал наилучший результат при обучении НС при использовании различных алгоритмов [12 – 14].

Выбор структуры НС. Для решения поставленной задачи был использован полносвязный МП прямого распространения. Сеть работает с меньшей погрешностью при использовании двух скрытых слоев. Для каждого нейрона скрытых слоев в качестве функции активации (ФА) использована логистическая функция, а для нейронов выходного слоя – линейная функция.

Для определения числа нейронов в скрытых слоях использован следующий способ. Построены и обучены НС для разных комбинаций количества нейронов в каждом слое из диапазонов 10 – 20. В каждом случае выделялись четыре функционала качества работы сети: ширина разброса абсолютной погрешности (разница между максимальным и минимальным значениями) на тестовой выборке (для k и T) и средняя относительная погрешность (для k и T). Далее анализировались матрицы разброса и средней относительной погрешности, по которым определены наименьшие значения функционалов и координаты этих точек. Координатами является количество нейронов в первом и втором скрытых слоях. Из полученных структур была выбрана оптимальная, а именно – НС с 14 нейронами в первом и 15 – нейронами во втором скрытом слое. Число входов сенсорного слоя равно 6, выходного – 2.

Обучение НС. НС обучилась за 600 эпох обучения. Суммарная квадратичная ошибка обучения (сумма квадратов ошибок S_{kv}) составила $9,93 \cdot 10^{-4}$. На рис. 2 приведен график процесса обучения.

Проверка качества идентификации. Среднее значение относительной погрешности коэффициента усиления равно 0,11% и постоянной времени – 1,72%. Однако основным показателем качества идентификации является максимальная степень совпадения переходных процессов реального ОУ и его модели, построенной с использованием полученных в результате идентификации параметров i -го набора коэффициента усиления k^i и постоянной времени T^i . Передаточная функция такой модели имеет вид:

$$W_I^i(p) = \frac{k^i(t)}{T^i(t)p + 1}. \quad (4)$$




Рис. 2. Процесс обучения НС

Для проверки качества нейросетевого идентификатора сравнение было проведено по всей тестовой выборке. Критерием качества выбрано среднее значение относительной погрешности $\bar{\varepsilon}$, рассчитанное при сравнении ОУ (1) и идентификационной модели (4) по формуле:

$$\bar{\varepsilon} = \frac{1}{N} \sum_{n=1}^N \frac{|y_n - y_n^i|}{y_n} \cdot 100\%, \quad (5)$$

где N – количество отсчетов ПП; y_n – n -й отсчет ПП ОУ; y_n^i – n -й отсчет ПП идентификационной модели.

Среднее значение $\bar{\varepsilon}$ составило 0,3835 %.

Структура спроектированного нейросетевого идентификатора представлена на рис. 3.




Рис. 3. Структура идентификатора на основе нейронной сети

На рис. 3 обозначено: X , Y – векторы входов и выходов ОУ; I – совмещенный вектор входов и выходов ОУ длиной 6, вход идентификатора; I_n – выходной вектор нормированного вектора блока нормализации; C_n – выходной вектор НС; C – вектор идентифицируемых параметров (выход идентификатора).

Блок формирования входа содержит 4 блока задержки, в результате чего на выходе блока формируется совмещенный вектор I , содержащий текущее значение входного сигнала и 5 последних значений выходного сигнала ОУ. В блоке нормализации вектор I_n рассчитывается на основании формулы (3). В

блоке денормализации вектор C рассчитывается из вектора C_n , основываясь на обратной формуле:

$$P = \left| P_n \sigma_o + \overline{P} \right|. \quad (6)$$

Таким образом, решена задача нейросетевой идентификации апериодического звена, причем рассчитанные значения берутся положительными, чтобы избежать возможного появления отрицательных значений параметров.

Идентификация параметров колебательного звена. В качестве искомых параметров для колебательного звена выбраны параметры ПФ (2), в частности, коэффициент усиления k , постоянная времени T и коэффициент демпфирования ξ .

Выбор структуры и формирование обучающей и тестовой выборок для колебательного звена выполнены аналогично тому, как было описано в предыдущем разделе "Идентификация параметров апериодического звена". Разница в формировании обучающей и тестовой выборок состоит в том, что были выбраны значения из диапазонов: $k = \overline{1, 20}$, $T = \overline{1, 20}$, $\xi = \overline{0, 1}$, а число последних дискретных значений выходного сигнала, по которым производится идентификация, принято равным 10. Такое увеличение дискретных значений выходного сигнала продиктовано тем, что график ПП колебательного звена имеет более сложную форму, чем апериодического.

Кроме того, в данном случае Байесова регуляризация показала худший результат и НС обучалась при помощи алгоритма Левенберга-Марквардта.

В итоге построена НС с тремя скрытыми слоями по 13 нейронов в каждом и с 3 нейронами в выходном слое. В качестве функции активации нейронов скрытых слоев выбрана тангенциальная функция, а выходного – линейная.

Обучающая выборка имеет длину 2000 векторов, тестовая – 3500. Входы и выходы НС нормировались аналогичным образом по формуле (3).

НС обучилась за 5000 эпох обучения. Суммарная квадратичная ошибка обучения (сумма квадратов ошибок $S_{\text{кв}}$) составила $1,08 \cdot 10^{-3}$. На рис. 4 приведен график процесса обучения сети.

Проверка качества идентификации также проходила по аналогии с апериодическим звеном. критерием качества было выбрано среднее значение относительной погрешности $\bar{\varepsilon}$, рассчитанное по формуле (5) при сравнении ОУ (2) и идентификационной модели (7)

$$W_{II}^i = \frac{k^i(t)}{\left(T^i(t)\right)^2 p^2 + 2\xi^i(t) \cdot p + 1}. \quad (7)$$




Рис. 4. Процесс обучения сети

Средние значения относительной погрешности идентификации коэффициента усиления, постоянной времени и коэффициента демпфирования соответственно равны 0,77 %, 3,88 %, 3,12 %. Однако, несмотря на высокую погрешность, сравнение ПП реального ОУ и его идентифицированной модели показало хороший результат. Среднее значение относительной погрешности $\bar{\epsilon}$ составило 0,8118 %.

Выводы. Таким образом, в результате проведенных исследований созданы и обучены нейронные сети, на базе которых построены идентификаторы типовых динамических звеньев. Обобщенная структурная схема идентификатора на базе НС приведена на рис. 3.

Предложенный подход может быть применен при идентификации объектов с изменяющимися параметрами для повышения точности управления. Перспективным является разработка подхода к нейросетевой идентификации технологических объектов в процессе эксплуатации.

Список литературы: 1. Цыпкин Я.З. Адаптация и обучение в автоматических системах / Я.З. Цыпкин. – М.: Наука, 1968. – 399 с. 2. Кондратенко Ю.П. Система адаптивной идентификации многосвязных объектов / Ю.П. Кондратенко // Труды НКИ. – Николаев: НКИ. – 1978. – № 137. – С. 90-92. 3. Ткаченко А.Н. Исследование на ЦВМ системы адаптивной идентификации турбогенератора как двухсвязного объекта / А.Н. Ткаченко, Ю.П. Кондратенко, А.П. Гуров // Кибернетика на морском транспорте. – 1979. – № 8. – С.116-120. 4. Махотило К.В. Разработка методик эволюционного синтеза нейросетевых компонентов систем управления: диссертация на соискание степени кандидата технических наук: 05.13.06 / К.В. Махотило. – Харьков, 1998. – 179 с. 5. Эффективная нейросетевая идентификация инверсной динамики объекта управления для синтеза прогнозирующих систем управления / Б.С. Ноткин // Идентификация и задачи управления SICPRO'05: Труды IV Междунар. конф., 25-28 янв. 2005. – [Электронный ресурс] – Режим доступа: <http://www.reshebnik.net.ru/getfile.php?nf=pin.pdf>. 6. Агамалов О.Н. Оценка технического состояния электрооборудования в реальном масштабе времени методом нейро-нечеткой идентификации / О.Н. Агамалов // ExponentaPro. Математика в приложениях. – 2003. – № 12. – С. 36-44. 7. Кубрак А.І. Комп'ютерне моделювання та ідентифікація автоматичних систем / А.І. Кубрак, А.І. Жученко, М.З. Кваско. – К.: Політехніка, 2004. – С. 123-190.

8. Хрящев В.В. Нейросетевой подход к решению задачи восстановления амплитуды дискретного сигнала / В.В. Хрящев, Е.Ю. Саутов, Е.А. Соколенко // Проектирование инженерных и научных приложений в среде MATLAB: труды конф., 2002. – [Электронный ресурс] – Режим доступа: <http://matlab.exponenta.ru/conf2002/theses/section4/hryashev/hryashev.php> 9. Антошук С.Г. Нейросетевая аппроксимация динамических характеристик систем электропривода / С.Г. Антошук, А.А. Николенко, Н.Ю. Хитрук // Електромашинобудування та електрообладнання. – Вип.66. – К.: Техніка, 2006. – [Электронный ресурс] – Режим доступа: http://nbuv.gov.ua/portal/natural/emeo/ee_66/7-05.pdf 10. Дьяконов В. Математические пакеты расширения MATLAB. Специальный справочник / В. Дьяконов, В. Круглов. – СПб.: Питер, 2001. – 475 с. 11. Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потемкин / Под общ. ред. В.Г.Потемкина – М.: ДИАЛОГ-МИФИ, 2002. – 496 с. 12. Губарев В.Ф. Исследование метода итеративной идентификации многомерных дискретных систем / В.Ф. Губарев, А.О. Жуков // Проблемы управления и информатики. – 2008. – № 5. – С. 23-28. 13. Губарев В.Ф. Исследование условий идентифицируемости при итеративной идентификации дискретных стационарных систем / В.Ф. Губарев, А.О. Жуков // Системні дослідження та інформаційні технології. – 2009. – № 1. – С. 100-115. 14. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилинский, Л. Рутковский. – М.: Горячая линия-Телеком, 2006. – 383 с.

УДК 004.896:681.518

Нейромережевий підхід до рішення задачі ідентифікації нестационарних параметрів технологічних об'єктів / Ю.П. Кондратенко, Е.В. Гордиенко // Вісник НТУ "ХПІ". Тематичний випуск: Інформатика і моделювання. – Харків: НТУ "ХПІ". – 2010. – № 21. – С. 102 – 109.

Розглянуті існуючі способи ідентифікації технологічних об'єктів. Запропонований нейромережевий підхід до рішення даної задачі і продемонстровані результати його вживання на прикладі ідентифікації параметрів типових динамічних ланок. Обґрунтований вибір архітектури і алгоритму вчення нейронної мережі. Л.: 4. Бібліогр.: 14 назв.

Ключові слова: ідентифікація технологічного об'єкту, нейронна мережа, динамічні ланки.

UDC 004.896:681.518

Neuronets going near decision of task of authentication of non-stationary parameters of technological objects / Yu.P. Kondratenko, E.V. Gordienko / Herald of the National Technical University "KhPI". Subject issue: Information Science and Modelling. – Kharkov: NTU "KhPI". – 2010. – №. 21. – P. 102 – 109.

The existent methods of authentication of technological objects are considered. The нейросетевой going is offered near the decision of this task and the results of his application are shown on the example of authentication of parameters of model dynamic links. The choice of architecture and algorithm of teaching of neuron network is grounded. Figs.: 4. Refs.: 14 titles.

Keywords: authentication of technological object, neuron network, dynamic links.

Поступила в редакцию 15.04.2010.