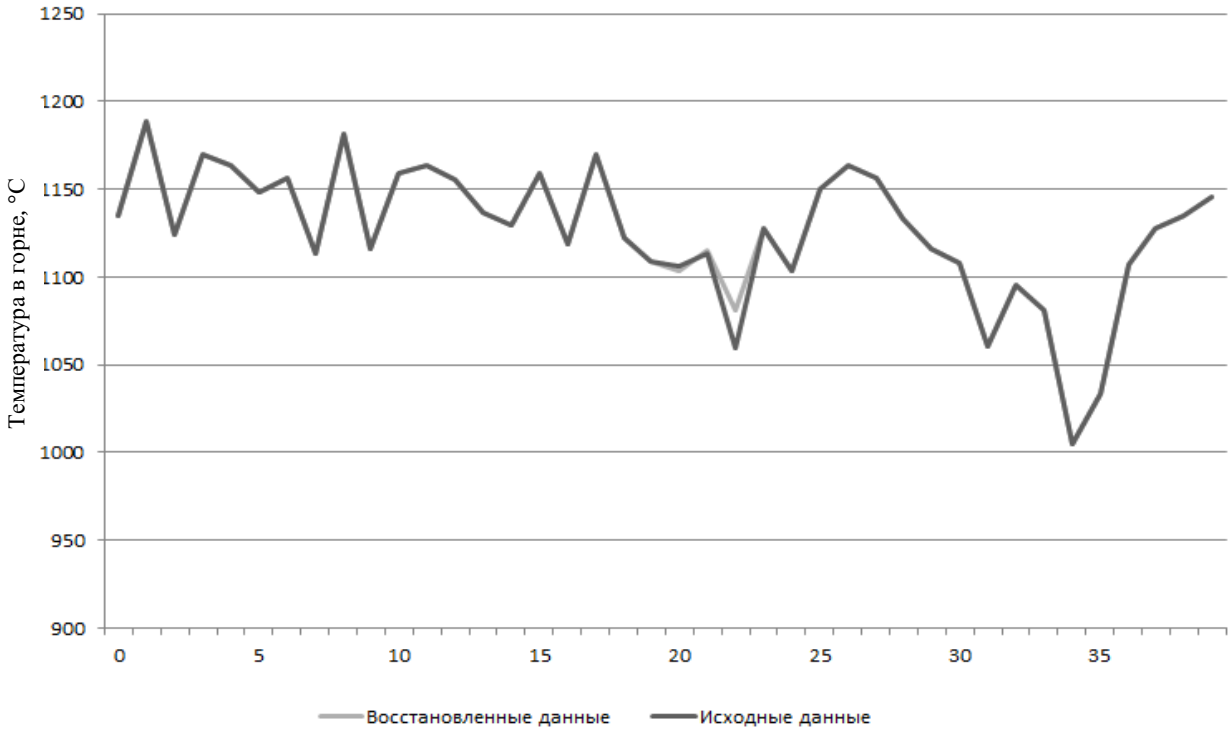


Рис. 2. Графики изменения температуры в секциях зажигательного горна

Таким образом, в системе прогнозирования электропотребления на агломерационном производстве целесообразно использовать алгоритм восстановления пропущенных значений, который повышает достоверность прогнозных значений. В основе алгоритма восстановления информации лежит использование метода интерполяции сплайнами для одиночных пропусков и Zet-алгоритма для групповых пропусков, причем первыми восстанавливаются одиночные пропущенные элементы, а затем полученная выборка обрабатывается с помощью Zet-алгоритма. В статье проанализированы результаты применения описанного метода, сделан вывод, что предложенный алгоритм чувствителен к резким скачкам в показателях, но на участках, где функция изменения значений во времени имеет гладкий график, элементы восстанавливаются с высокой точностью.

Литература

1. *Де Бор, К.М.* Практическое руководство по сплайнам / К.М. Де Бор. – М., 1985.
2. *Загоруйко, Н.Г.* Алгоритм заполнения пропусков в эмпирических таблицах (алгоритм Zet) / Н.Г. Загоруйко, В.Н. Елкина, В.С. Тимеркаев // Эмпирическое предсказание и распознавание образов. – Новосибирск, 1975. – Вып. 61: Вычислительные системы. – С. 3 – 27.
3. *Литтл, Р.Дж.А.* Статистический анализ данных с пропусками / Р.Дж.А. Литтл, Д.Б. Рубин. – М., 1990.

УДК 621.313.2:681.513.7:004.896

В.Н. Волков, А.В. Кожевников

ПОСТРОЕНИЕ ЭТАЛОННОЙ МОДЕЛИ ЭЛЕКТРОПРИВОДА ПОСТОЯННОГО ТОКА С ИСПОЛЬЗОВАНИЕМ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

В статье рассматривается использование искусственной нейронной сети для идентификации электропривода постоянного тока. Модель может быть использована для построения эталонных моделей в адаптивных системах.

Электропривод, самонастройка, эталонная модель, нейронные сети, адаптивные системы.

The use of an artificial neural network for identification of DC drive is considered in the article. The model can be used for constructing the reference models in adaptive systems.

Electric drive, self-adjustment, reference model, neural networks, adaptive systems.

В современных промышленных установках предъявляется высокие требования к качеству регулирования электрическим приводом. Это связано с усложнением технологических операций, где становится критичной точность отработки исполнительным механизмом задающего воздействия. Во многих установках предполагается работа в условиях изменяющихся параметров нагрузки и параметров электродвигателя.

До настоящего времени в большинстве реальных систем управления применяется способ подчиненного регулирования из-за простоты его реализации. При всех его достоинствах основным недостатком такого способа регулирования является повышенная чувствительность к изменению параметров объекта регулирования. Для поддержания качества регулирования электропривода в этом случае вводят контуры адаптации. При решении задачи адаптации наибольшее распространение получили беспоисковые адаптивные системы управления, детально разработанные в теории автоматического управления. Один из классов подобных систем представляет собой адаптивную систему с эталонной моделью. В качестве эталонной модели строится динамическое звено с желаемой динамикой [6].

Классические методы построения эталонной модели предполагают разработку передаточной функции объекта. При этом требуется построение адекватной математической модели объекта, что не всегда возможно достичь. Это связано с тем, что реальный электропривод с исполнительным механизмом могут представлять собой многомассовую систему с существенными нелинейностями, которые невозможно учесть в модели.

Альтернативным инструментом для построения эталонных моделей может быть рекуррентная нейронная сеть. Она не требует знания математической модели объекта и учитывает нелинейность объекта за счет нелинейных функций активации нейронов в своей структуре [4], [7]. В источниках [2], [3], [5] описаны способы идентификации динамических объектов при помощи нейронных сетей. Согласно теореме об универсальной аппроксимации многослойного персептрона (многослойной нейронной сети) с одним скрытым слоем достаточно для построения равномерной аппроксимации с точностью ε для любого обучающего множества, представленного входам $x_1, x_2, \ldots, x_{m0}$ и желаемых откликов $f(x_1, x_2, \ldots, x_{m0})$ [1], [7]. Таким образом, нейронную сеть можно обучить отображать соотношения «вход–выход» объектов при наличии достаточного количества обучающих примеров в пределах рабочего диапазона объекта. Имеется множество публикаций и работ по идентификации обобщенного динамического объекта. Несмотря на это, мало работ по нейросетевой идентификации объектов конкретных типов, и решения имеют частный характер [2].

В данной работе рассмотрен вопрос применения нейронной сети для идентификации электромеханического динамического объекта – электропривода постоянного тока. Для упрощения эксперимента использовался электродвигатель прокатного стана с известными постоянными времени Tя, Tм, Tв, достаточными для построения математической модели методами классической теории автоматического управления. Преобразователь для упрощения представлен апериодическим звеном $\frac{1}{T_n s+1}$.

Моделирование производилось в приложении *Simulin*k среды разработки *Matlab* в три этапа:

– на первом этапе на модель двигателя подавался случайный процесс для получения обучающего множества входных и выходных данных;

– на втором этапе производился выбор структуры нейронной сети и ее обучение;

– на третьем – на классическую модель и на нейросетевую подавалось одинаковое задание и момент сопротивления, после чего сравнивались выходы на корректность отображения.

На первом этапе для получения статистических данных об объекте была построена схема (рис. 1). Для удобства восприятия части схемы с общим функциональным назначением объединены в блоки.

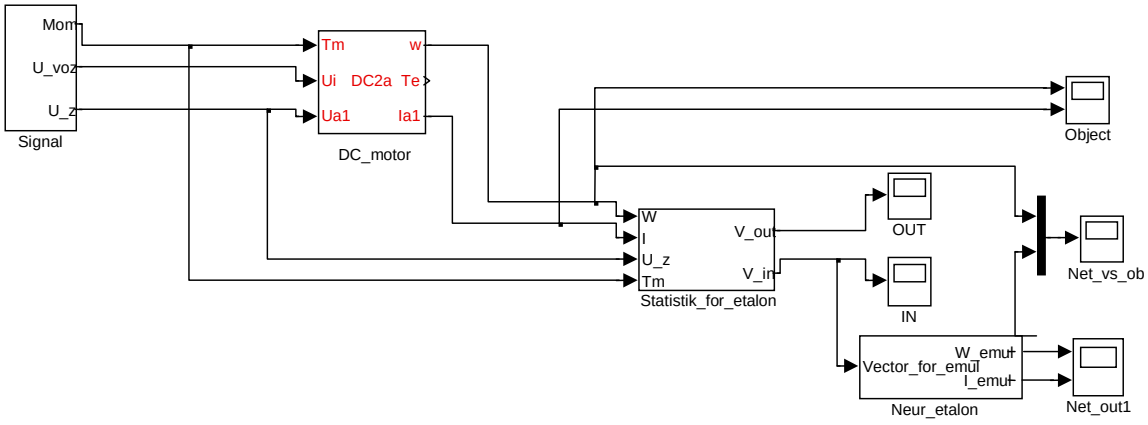


Рис. 1. Схема в *Simulink* для моделирования электропривода и нейросетевой эталонной модели

В качестве измеряемых величин определены: входное напряжение $U_{вх}$, ток якоря $I_я$, скорость W и момент на валу двигателя $M_н$. Случайный процесс, длительностью 240 с, подавался на входы $U_я$ и $M_н$. Выходы снимались с W и $I_я$. Данные приводились к безразмерному виду и считывались в рабочую среду *Matlab*.

На втором этапе эксперимента была выбрана архитектура нейронной сети, определены необходимые входы и выходы и выбран способ оптимизации весов.

В [2], [5], [7] приводятся разные архитектуры нейронных сетей для идентификации обобщенного динамического объекта. В эксперименте использовалась рекуррентная двухслойная сеть с обратными связями от выходных сигналов с задержкой (рис. 2). Такой тип сети известен как модель нелинейной регрессии с внешними входами *NARX* [7]. Эта сеть получается из многослойного персептрона путем введения обратных связей. Такая структура помогает запоминать сети последовательности сигналов, что важно для аппроксимации динамических объектов. Обобщенная модель имеет следующее форму:

$$y(n+1) = \varphi\,(y(n), \ldots y(n-q+1), u(n), \ldots, u(n-q+1)) \quad (1)$$

где $y(n)$ – выходной вектор, $u(n)$ – входной вектор, n – дискретный момент времени, q – порядок системы.

В нейронных сетях с обратными связями в отличие от однонаправленных сетей существует проблема устойчивости сети. В сети типа NARX отсутствуют подобные проблемы благодаря единичной задержке z^{-1} сигналов обратных связей с выходов. Наличие задержки выходного сигнала с обратной связи исключает смешивание сигналов и обеспечивает сети устойчивость.

Вычислительная мощность сети прямо пропорциональна количеству нейронов в скрытом слое, но с увеличением количества нейронов сеть может утратить способность к аппроксимации, т.е. будет хорошо повторять учебные примеры, но не сможет адекватно отражать новые данные. В настоящее время нет точного способа определить необходимое число нейронов во внутреннем слое, и это определяется эвристически проверкой на корректность разных вариантов сети. На рис. 2 приведена упрощенная схема сети *NARX*.

В данной работе в качестве входов использовались: напряжение на входе $U_{вх}$ и момент нагрузки $M_н$ и их единичные задержки z^{-1}. В качестве выходов использовались: скорость W и ток якоря $I_я$, которые также через единичные задержки z^{-1} были заведены в обратную связь.

Перед обучением были произведены настройки внутренней структуры сети и выбраны параметры обучения в среде Matlab [3]. Во внутреннем слое сети применена гиперболическая тангенциальная функция активации $\tan sig(N) = \frac{2}{1+e^{2N}} - 1$, где $N = \sum_{j=0}^{j} U_j \cdot W_{ij}$ – сумма произведений входного вектора и весовых коэффициентов первого слоя. Количество нейронов внутреннего слоя эмпирически выбрано равным 5.

В выходном слое задана линейная функция активации $purelin\,(N) = N$, где N – сумма произведений выходов нейронов внутреннего слоя на весовые коэффициенты выходного слоя.

Для обучения сети использовался алгоритм Левенберга-Марквардта, в Matlab он представлен функцией *trainlm*. Обучение производилось в течение 300 итераций, при этом ошибка обучения Err = $= 4 \cdot 10^{-7}$.

На третьем этапе эксперимента обученная сеть была подключена к схеме (рис. 1) в блоке *Neur_etalon*, в который поданы входные сигналы и собственные выходные сигналы сети. Для проверки корректности сети на входы поочередно были поданы три величины входного напряжения $U_{вх}$, и моделировался разгон электродвигателя, движение без ускорения и остановка. Время моделирования – 30 с. Одновременно те же сигналы были поданы на модель электропривода. Результаты моделирования отображены на графике (рис. 3). Сплошной линией изображена скорость модели, штриховой линией – аппроксимация скорости нейронной сетью. Из графика видно, что нейронная сеть смогла практически идеально воспроизвести скорость объекта при различных входных заданиях $U_{вх}$.

После работы сети при разных входных заданиях была произведена проверка при моделировании подачи момента сопротивления. Для наглядности отображаемых результатов на модель электропривода и нейросетевую модель был подан стохастически изменяющийся момент сопротивления. Результаты моделирования показывают (рис. 4), что отклонение нейросетевой модели также достаточно мало. Среднеквадратичное отклонение не превышает 0,0018 рад/с.

При многократном повторении всех этапов эксперимента нейронная сеть показывает стабильность результатов моделирования. По результатам эксперимента можно сделать вывод о возможности применения рекуррентной нейронной сети для построения эталонных моделей электроприводов постоянного тока. Решающим условием ее эффективности остается наличие достаточного количества обучающих примеров для всего диапазона скоростей и моментов сопротивления в реальной промышленной установке.

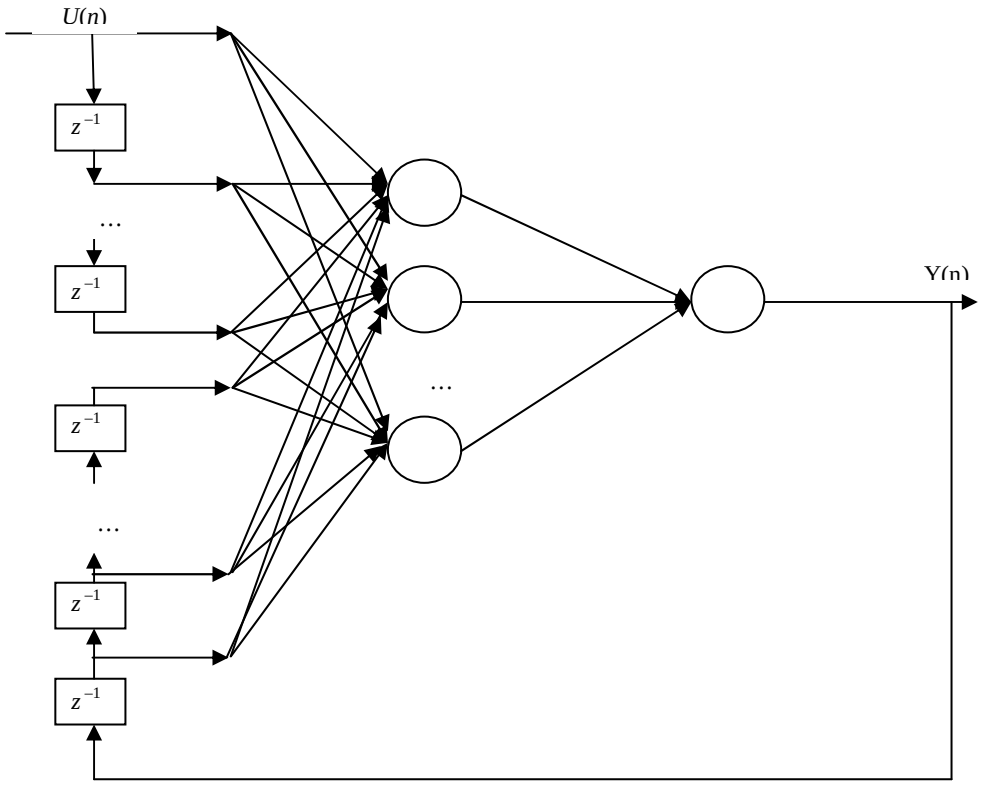


Рис. 2. Рекуррентная нейронная сеть NARX

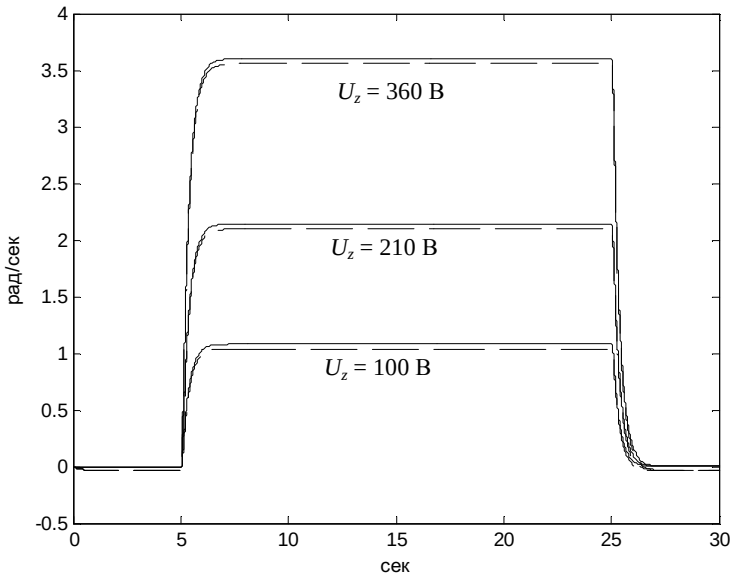


Рис. 3. Сравнительное моделирование при различных входных заданиях $U_{вх}$ модели электропривода и нейросетевой модели идентификации

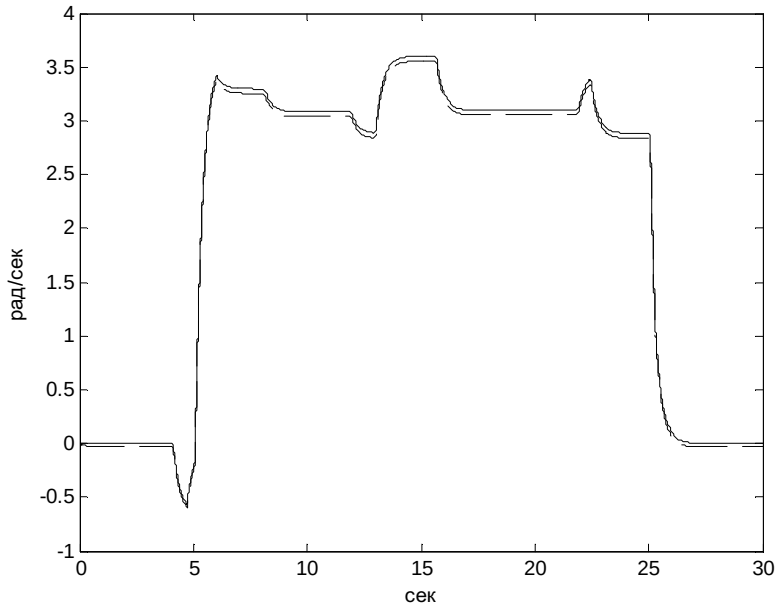


Рис. 4. Сравнительное моделирование работы модели электропривода и нейросетевой модели идентификации при случайном моменте сопротивления $M_н$.

Литература

1. *Горбань, А.Н.* Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей / А.Н. Горбань // Сибирский журнал вычислительной математики РАН. Сибирское отделение. – Новосибирск, 1998. –Т. 1. – № 1. – С. 11 – 24.

2. *Макаров, И.М.* Интеллектуальные системы автоматического управления / И.М. Макаров, В.М. Лохин. – М., 2001.

3. *Медведев, В.С.* Нейронные сети. MATLAB6 / В.С. Медведев, В.Г. Потемкин. – М., 2002.

4. *Оссовский, С.* Нейронные сети для обработки информации / С. Оссовский. – М., 2002.

5. *Терехов, В.А.* Нейросетевые системы управления / В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин. – М., 2002.

6. *Терехов, В.М.* Системы управления электроприводов / В.М. Терехов, О.И. Осипов. – М., 2006.

7. *Хайкин, С.* Нейронные сети: полный курс / С. Хайкин. – М., 2006.

УДК 621.43.016

З.К. Кабаков, И.А. Сенатова, А.Л. Кузьминов, А.И. Фоменко

ПОВЫШЕНИЕ ТОЧНОСТИ ЧИСЛЕННЫХ МОДЕЛЕЙ ТЕПЛООБМЕНА В НЕПОДВИЖНОМ СЛОЕ

В статье рассмотрен сравнительный анализ алгоритмов тестирования численного решения уравнений теплообмена для газа и материала в неподвижном слое и предложен усовершенствованный алгоритм тестирования численной модели процесса теплообмена, что позволяет увеличить точность решения.

Уравнения теплообмена, численное решение, тестирование алгоритмов, максимальные относительные погрешности.

The article presents a comparative analysis of algorithms for testing the numerical solutions of equations of heat transfer for gas and material in a fixed bed and an improved algorithm for testing the numerical model of heat transfer process, which increased the accuracy of the solution.

Convection equations, numerical solution, testing algorithms, the maximum relative error.

При рассмотрении процессов теплообмена в плотном неподвижном слое используют математическую модель, которая включает следующие уравнения [5]: уравнение теплообмена для газа

$$c_г \rho_г w_г \frac{\partial t_г}{\partial y} = -\alpha_V \left(t_г - t_м \right) \qquad (1)$$

и уравнение теплообмена для материала