

СПИСОК ЛИТЕРАТУРЫ

1. Пат. РФ № 2244048: МПК С30В13/16. Способ зонной плавки и устройство для его осуществления / В. Х. Забаровский; заявитель и патентообладатель В. Х. Забаровский; № 2000116804/02; заявл. 23.06.2000; Опубл. 10.01.2005.
2. Пфанн В. Зонная плавка. М.: Мир, 1970.
3. Управление фронтом кристаллизации расплава при непрерывно-последовательной зонной плавке в индукционной печи с холодным тиглем / М. Ю. Максименко, И. В. Позняк, А. Н. Шатунов, А. Ю. Печенков, В. В. Кичигин, А. И. Максимов // Изв. СПбГЭТУ «ЛЭТИ». 2013. № 3. С. 73–78.
4. Петров Ю. Б. Индукционная плавка окислов. Л.: Энергоатомиздат. Ленингр. отд-ние, 1983.
5. Петров Ю. Б. Индукционная плавка оксидов в холодных тиглях; дис. ... д-ра техн. наук: 05.09.10. Л., 1986.
6. Суворова М. Ю., Позняк И. В. Верификация фронта кристаллизации и скорости перемещения тигля относительно индуктора при зонной плавке в холодном тигле // Тр. X Всерос. науч. конф. молодых ученых «Наука. Технологии. Инновации». Новосибирск (НТИ-2017). Ч. 5. Новосибирск: Изд-во НГТУ, 2017. С. 59–63.

M. Yu. Suvorova, I. V. Poznyak
Saint Petersburg Electrotechnical University «LETI»

FORMULATION OF THE PROBLEM OF STUDYING THE SHAPE OF THE CRYSTALLIZATION FRONT DURING ZONE MELTING IN AN INDUCTION FURNACE WITH A COLD CRUCIBLE

Presents the results of research on the technology of purification of spent nuclear fuel (SNF) on the basis of multiple crystallization of the melt in an induction furnace with a cold crucible during by zone melting. The work was carried out to study the form of the melt crystallization front at different speeds of the crucible relative to the inductor. The generalized mathematical model of SNF cleaning process is developed, the algorithm of the program operation is presented. Numerical simulation of melt crystallization processes is carried out, as well as theoretical calculation of the system parameters to obtain the best result. Verification of the data obtained by numerical simulation with the data of full-scale experiment is carried out. The verification results indicate that the developed model of the crystallization front shape is reliable for calculations.

Zone melting, induction heating, cold crucible, purification of spent nuclear fuel, front of crystallization

УДК [62.83:621.94]:004.32.26

М. П. Белов, И. С. Носиров, А. М. Белов
Санкт-Петербургский государственный электротехнический
университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

Синтез нейросетевого регулятора для двухмассовой электромеханической системы привода подачи токарного станка

Рассмотрен анализ преимуществ и недостатков нейроконтроллера с предсказанием (Neural Network Predictive Controller), реализованного в пакете прикладных программ Neural Network Toolbox. Приведено математическое описание двухмассовой электромеханической системы привода подачи токарного станка с упругими связями. Рассмотрена процедура синтеза нейрорегулятора для стабилизации скорости линейного движения и компенсации колебаний, возникающих в упругих элементах приводов подачи токарных станков. Приведены сравнительные исследования нескольких алгоритмов: Моллера, Левенберга–Марквардта, Полка–Рибера, градиентного спуска, для обучения нейрорегулятора NARMA-L2 Controller. Определены параметры нейрорегулятора NARMA-L2 Controller, существенно влияющие на качество управления. Приводится сравнительный анализ показателей качества обучения нейросетевого регулятора при различных алгоритмах обучения. Показано, что применение нейросетевого регулятора NARMA-L2 Controller позволяет улучшить качество показателей системы управления (СУ) привода подачи токарного станка.

Электромеханическая система, привод подачи токарного станка с упругими связями, нейрорегулятор, алгоритм обучения Левенберга–Марквардта

Постановка проблемы. При проектировании металлорежущих станков на первый план выдвигаются проблемы повышения точности и производительности. В процессе механической обра-

ботки все элементы металлорежущих станков подвергаются воздействию силы резания, упругим колебаниям, а также деформациям обрабатываемой поверхности, что приводит к колебаниям элементов станка. Наибольший вклад в колебания элементов станка вносят упругие колебания в приводе подачи, что связано с его большой податливостью. Упругие колебания отрицательно влияют на работу приводов подачи, вызывая увеличение динамических нагрузок на элементы, снижение быстродействия и точности при отработке программных траекторий, появление незатухающих вибраций, опасных резонансных явлений и т. п. Таким образом, для достижения требуемого качества обработки с точки зрения кинематики приводов подачи требуется решение задачи компенсации упругих колебаний в приводах подачи, возникающих под воздействием силы резания. Существуют различные способы компенсации упругих колебаний [1]. Один из подходов представляет ограничение среднего ускорения электропривода, когда увеличивается время переходного процесса привода, что ведет к снижению производительности. Альтернативой может быть ограничение темпа нарастания динамического момента – недостатки у этого способа такие же, как и у вышеупомянутого.

В настоящее время развивается перспективный метод управления на основе применения технологий искусственного интеллекта (нейронных сетей, генетических алгоритмов, нечеткой логики и т. д.). СУ с нейронными сетями (НС) в отличие от классических методов управления имеют способность к обучению и самообучению. Таким образом, актуальной задачей исследования становится применение нейронных сетей для стабилизации скорости линейного движения суппорта и компенсации колебаний, возникающих в упругих элементах приводов подачи токарных станков.

Изложение материала исследования и полученных научных результатов. В NN Toolbox системы MATLAB/Simulink реализованы три архитектуры нейронных сетей в виде следующих нейроконтроллеров [2]: нейроконтроллер с предсказанием (Neural Network Predictive Control), нейроконтроллер на основе модели авторегрессии со скользящим средним (NARMA-L2 Controller) и нейроконтроллер на основе эталонной модели (Model Reference Controller). Как показали исследования, наиболее эффективен для разработки нейросетевой системы управления скоростью линейного движения суппорта токарного станка

нейроконтроллер с предсказанием. Он использует нелинейный управляемый объект в виде многослойной прямой нейронной сети для прогнозирования будущего поведения объекта. Кроме того, NN Predictive Control способен вычислять сигнал управления, который оптимизирует поведение объекта на заданном интервале времени. Однако недостаток данного нейроконтроллера с предсказанием заключается в том, что процесс обучения может занимать длительное время и требует большого объема вычислений и сложен для практической реализации.

Поэтому в данной статье для решения поставленной задачи предлагается применить нейрорегулятор NARMA-L2 Controller. Далее приводится алгоритм синтеза данного нейросетевого регулятора при различных алгоритмах обучения.

Математическое описание привода подачи с упругими связями. При моделировании динамических процессов в СУ приводов подачи металлорежущих станков математическое описание кинематических схем предоставляют в виде многомассовых механических систем (ММС). Упрощенная расчетная двухмассовая электромеханическая система (ЭМС) взаимосвязанных электроприводов подачи токарного станка с упругими связями показана на рис. 1. Здесь в качестве первой массы J_1 принимается момент инерции асинхронного электропривода, вторая масса J_2 учитывает момент инерции ходового винта и момент инерции поступательно движущихся частей (суппорта и массы обрабатываемой детали) привода подачи токарного станка; b_{12} – коэффициент вязкого трения.

Одним из основных универсальных уравнений, позволяющих получить математическую модель, определяющую динамические характеристики механической подсистемы, является уравнение Лагранжа второго рода [3]

$$\sum_{i=1}^n \left[\frac{d}{dt} \left(\frac{\partial L}{\partial \dot{q}_i} \right) - \frac{\partial L}{\partial q_i} \right] = \sum_{i=1}^n Q_i. \quad (1)$$

Здесь t – время;

$$L = W_K - W_{\Pi} \quad (2)$$

– функция Лагранжа (W_K, W_{Π} – кинетическая и потенциальная энергии); q_i, \dot{q}_i – обобщенные координата и скорость i -й степени свободы; Q_i – внешние силы, действующие по каждой степени подвижности.

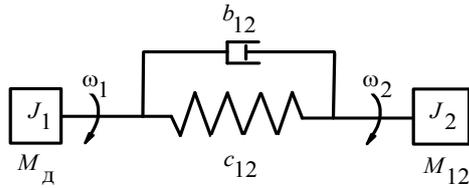


Рис. 1

Математическую модель двухмассовой системы привода подачи можно записать в виде

$$\begin{cases} \dot{\omega}_1 = J_1^{-1} [M_d - M_{12} - M_c]; \\ \dot{\omega}_2 = J_2^{-1} [M_{12} - M_c]; \\ \dot{M}_{12} = c_{12} (\omega_1 - \omega_2), \end{cases} \quad (3)$$

где ω_1, ω_2 – угловые скорости первой и второй масс; M_d – момент двигателя; M_{12} – упругий момент; M_c – статический момент на валу двигателя; c_{12} – коэффициент жесткости.

Нейросетевой регулятор NARMA-L2. В качестве модели управляемого объекта использует модель нелинейной авторегрессии со скользящим средним (Nonlinear Autoregressive-Moving Average – NARMA-L2). При синтезе данного нейрорегулятора учитывается, что если управляемый объект есть динамическая система, то необходимо строить его динамическую нелинейную модель со скользящим средним, или NARMA-модель в форме

$$\begin{aligned} y(k+d) = N[y(k), y(k-1), \dots, y(k-n+1), \\ u(k), u(k-1), \dots, u(k-n+1)], \end{aligned} \quad (4)$$

где d – сдвиг; N – функция, определяющая динамику системы; $y(k)$ – выход; n – номер итерации; $u(k)$ – вход.

Если стоит задача проектирования следящей системы управления, обеспечивающей движение по заданной траектории, то

$$y(k+d) = y_r(k+d), \quad (5)$$

$$\begin{aligned} u(k) = G[y(k), y(k-1), \dots, y(k-n+1), \\ y_r(k-d), u(k-1), \dots, u(k-n+1)]. \end{aligned} \quad (6)$$

Для обучения нейронной сети функции G и минимизации среднеквадратической ошибки необходимо использовать динамический метод обратного распространения ошибки. Это может потребовать большого количества вычислений. Контроллер основан на приближенной модели NARMA-L2:

$$\begin{aligned} \hat{y}(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), \\ u(k-1), \dots, u(k-n+1)] + g[y(k), y(k-1), \dots, \end{aligned}$$

$$y(k-n+1), u(k-1), \dots, u(k-n+1)]u(k), \quad (7)$$

где g – функция ошибки.

В этой модели следующий вход контроллера $u(k)$ не содержится внутри нелинейности. Текущее управление можно непосредственно вычислить, если известны желаемая траектория y_r , предшествующие значения управления и предшествующие и текущее значения выхода:

$$\begin{aligned} u(k) = \{y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), \\ u(k-1), \dots, u(k-n+1)]\} / \{g[y(k), y(k-1), \dots, \\ y(k-n+1), u(k-1), \dots, u(k-n+1)]\}, \end{aligned} \quad (8)$$

где f – функция.

В данном случае сигнал управления $u(k)$ зависит от текущего значения выхода $y(k)$, что затрудняет применение регулятора, поэтому будет использоваться следующая модель:

$$\begin{aligned} y(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), \\ u(k), u(k-1), \dots, u(k-n+1)] + \\ + g[y(k), y(k-1), \dots, y(k-n+1), u(k), \\ u(k-1), \dots, u(k-n+1)]u(k+1), \end{aligned} \quad (9)$$

где $d \geq 2$.

На рис. 2 показана структура нейронной сети. Используя модель NARMA-L2, можно получить следующее описание работы контроллера:

$$\begin{aligned} u(k+1) = \{y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), \\ u(k-1), \dots, u(k-n+1)]\} / \{g[y(k), \dots, y(k-n+1), \\ u(k-1), \dots, u(k-n+1)]\}, \end{aligned} \quad (10)$$

где $d \geq 2$.

Использование модели NARMA-L2 позволяет представить NARMA-L2 Controller в виде, показанном на рис. 2, где r – входное воздействие; e_r – значение ошибки; TDL – алгоритм настройки нейронного регулятора NARMA-L2 Controller.

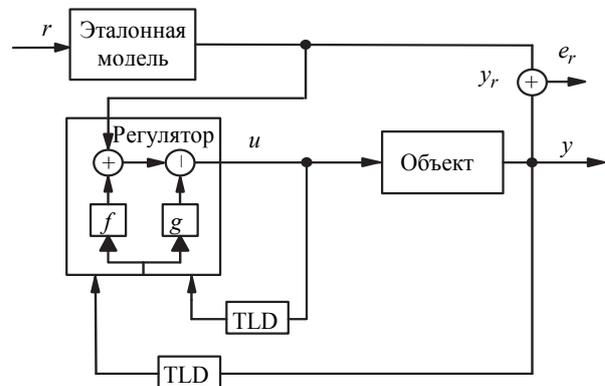


Рис. 2

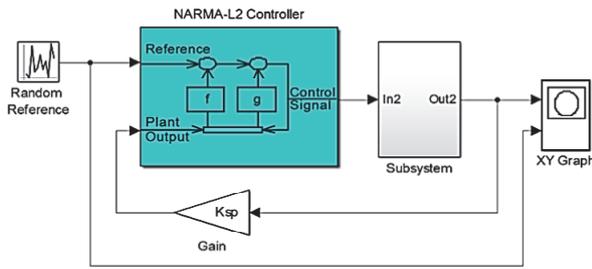


Рис. 3

полняет функции графического интерфейса пользователя (рис 5). Данное окно универсальное и может применяться для построения нейросетевых моделей для любого динамического объекта (в данной статье исследуемый объект – двухмассовая ЭМС привода подачи токарного станка).

При идентификации управляемого объекта задаются следующие параметры нейрорегулятора

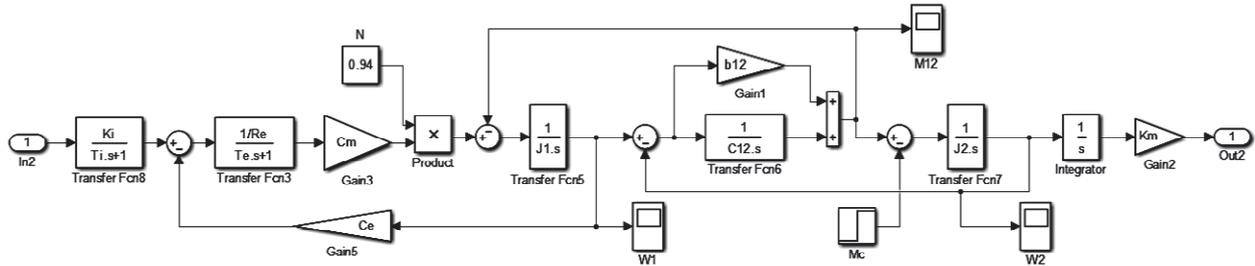


Рис. 4

Результаты компьютерного моделирования.

При синтезе нейросетевого регулятора NARMA-L2 Controller с целью стабилизации скорости линейного движения суппорта токарного станка рассмотрим структурную схему, показанную на рис. 3. Данная структура включает блоки: управляемого объекта Subsystem, нейрорегулятора NARMA-L2 Controller, генерации эталонного случайного сигнала Random Reference и построения графика. Параметры управляемого объекта приведены в [4]. Упрощенная схема модели объекта управления представлена на рис. 4.

Процедура синтеза нейрорегулятора выполняется активизацией блока NARMA-L2 Controller, в результате чего появляется окно идентификации (Plant Identification – NARMA-L2), которое вы-

полняет функции графического интерфейса пользователя (рис 5). Данное окно универсальное и может применяться для построения нейросетевых моделей для любого динамического объекта (в данной статье исследуемый объект – двухмассовая ЭМС привода подачи токарного станка).

полняет функции графического интерфейса пользователя (рис 5). Данное окно универсальное и может применяться для построения нейросетевых моделей для любого динамического объекта (в данной статье исследуемый объект – двухмассовая ЭМС привода подачи токарного станка). При выборе процедуры Generate Training Data запускается программа генерации обучающей последовательности на интервале 1500 с для модели двухмассовой ЭМС привода подачи токарного станка. Далее, по завершении генерации обучающей последовательности, можно начать обучение нейронной сети с помощью кнопки Train Network. Для обучения нейронной сети в настройках нейросетевого регулятора существуют различные функции обучения НС. В статье приводятся следующие алгоритмы: М. Ф. Моллера (Trainscg), Левенберга–Марквардта (Trainlm), Полка–Рибера (Traincgp), градиентного спуска (Traingdm) (табл. 2). Результаты обучения и тестирования на контрольном множестве отображены на рис. 6, а и б соответственно. Модель НС с прямой передачей сигнала NARMA-L2 Controller показаны на рис. 7. Разработанная НС имеет 6 слоев с 10 нейронами в первом и третьем слоях и 1 нейроном во втором, четвертом, пятом и шестом слоях.

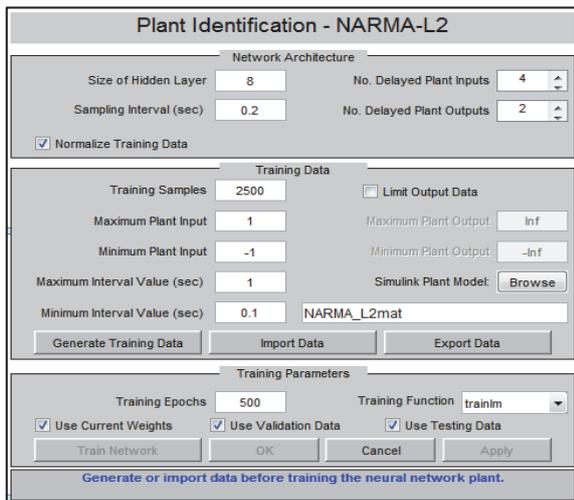


Рис. 5

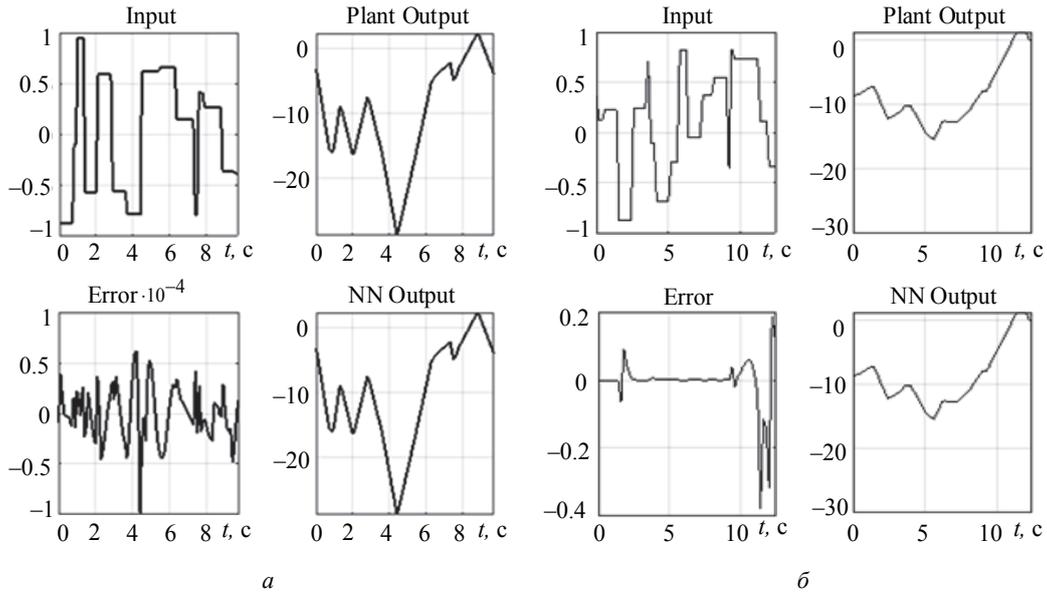


Рис. 6

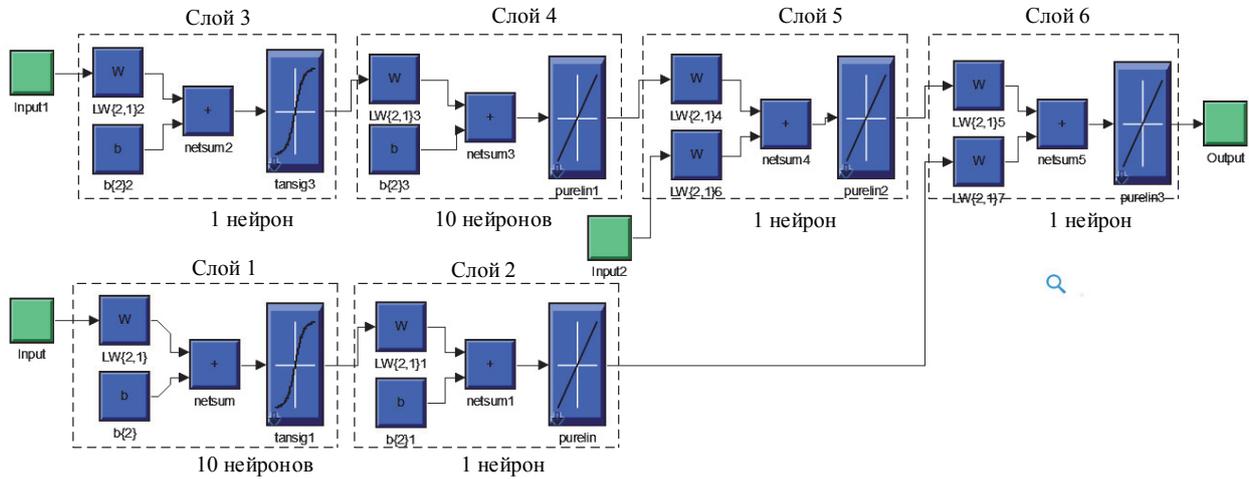


Рис. 7

Таблица 1

Параметр нейрорегулятора NARMA-L2 Controller	Обозначение	Вариант			
		<i>a</i>	<i>б</i>	<i>в</i>	<i>г</i>
Size of Hidden Layer	S	9	10	6	8
Sampling Interval, c	Δt	0.15	0.1	0.2	0.25
No. Delayed Plant Inputs	N_i	2	2	2	2
No. Delayed Plant Outputs	N_j	2	2	2	2
Training samples	N_B	1500	2500	2000	1000
Maximum Plant Input	φ_{\max}	1	1	1	1
Minimum Plant Input	φ_{\min}	-1	-1	-1	-1
Maximum Plant Output	β_{\max}	inf	inf	inf	inf
Minimum Plant Output	β_{\min}	-inf	-inf	-inf	-inf
Maximum Interval Value, c	t_{\max}	1	1	1	1
Minimum Interval Value, c	t_{\min}	0.1	0.1	0.1	0.1
Training Epochs	-	200	200	200	200

Успешное обучение нейросетевого регулятора в значительной степени зависит от количества используемых нейронов в скрытых слоях S , длины

обучающей выборки N_B и тактики дискретности Δt в секундах, определяет интервал между двумя последовательностями моментов съема данных.

Таблица 2

Параметр качества обучения нейрорегулятора NARMA-L2 Controller	Вариант			
	<i>a</i>	<i>б</i>	<i>в</i>	<i>г</i>
Градиент	2.64	1.86	32	23.3
Качество циклов обучения	187	198	158	80
Средняя ошибка обучения	$2.849 \cdot 10^{-3}$	$3.598 \cdot 10^{-9}$	$6.1 \cdot 10^{-2}$	$1.1 \cdot 10^{-2}$
Точность обучения	$2.38 \cdot 10^{-3}$	$1.51 \cdot 10^{-6}$	$2.8 \cdot 10^{-2}$	$3.74 \cdot 10^{-2}$
Время обучения, с	80	94	72	56
Алгоритм обучения	trainscg	trainlm	traincgp	traingdm

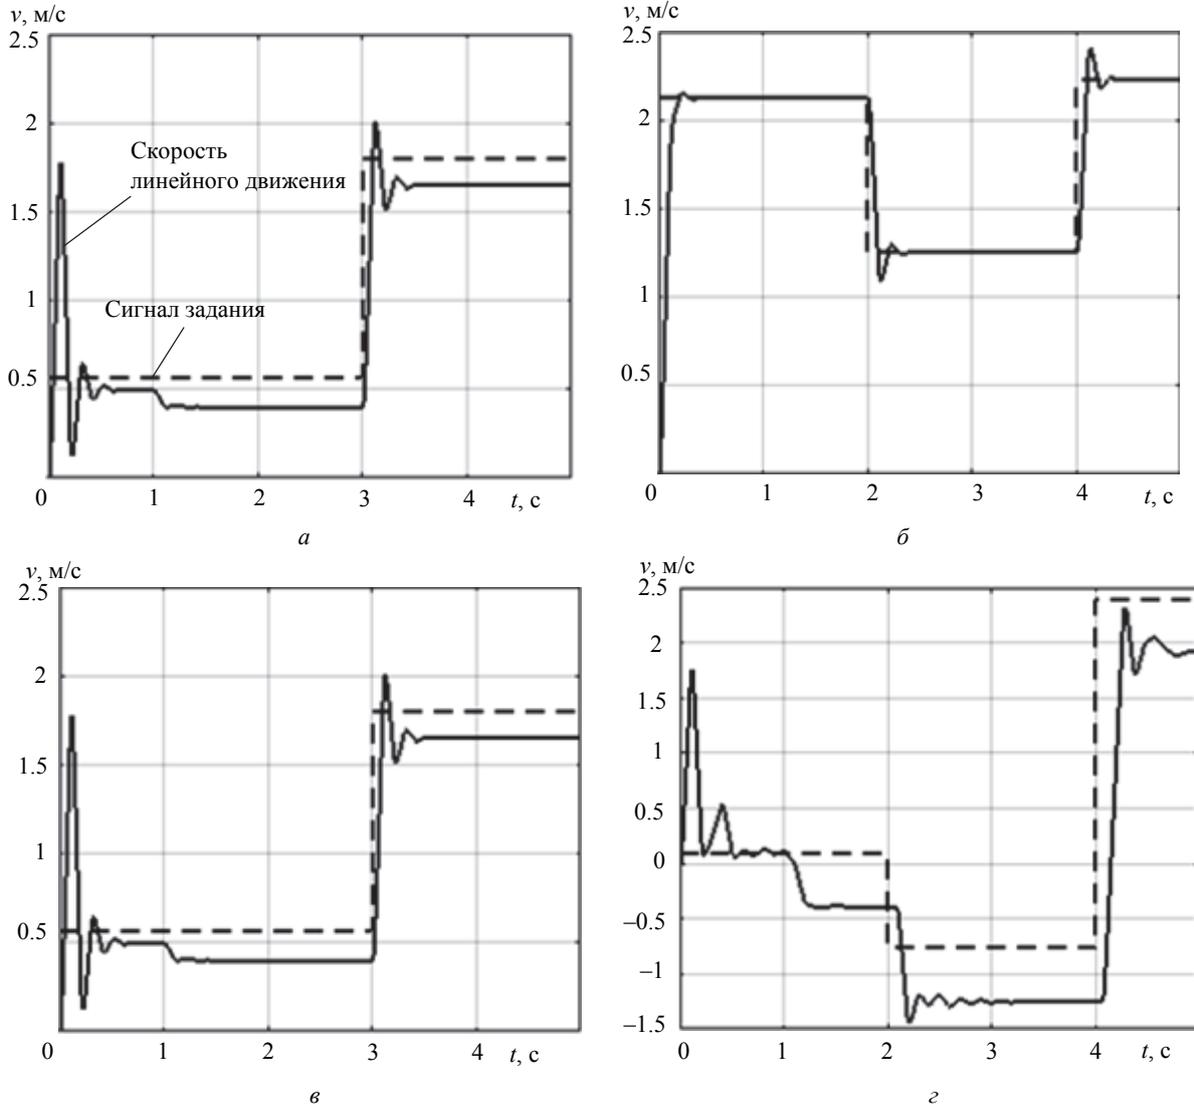


Рис. 8

Как показали исследования при настройке нейросетевого регулятора, одновременное изменение нескольких параметров архитектуры НС в окне идентификации (рис. 5), приводит к усложнению процесса настройки нейросетевого регулятора NARMA-L2 Controller. Чтобы добиться хороших результатов настройки, необходимо варьировать параметры по одному.

Например, в параметрах архитектуры НС в определенных пределах варьировем количество

используемых нейронов S , а дискретность Δt в секундах принимаем постоянной, т. е. $\Delta t = 0.15$ с в табл. 1. При выполнении данной процедуры, если НС не удовлетворяет поставленной задаче, то переходим к варьированию параметров обучающей последовательности и обучения нейросетевого регулятора. Таким способом можно обучить нейросетевой регулятор, который обеспечивает выполнение поставленной задачи.

В ходе исследования было доказано, что выбор количества нейронов S в зависимости от сложности динамики управляемого объекта, т. е. если выбрать количество нейронов больше ожидаемого, то наблюдается переобучение, и процесс обучения может занимать длительное время, а при малом количестве нейронов сеть не может выполнить поставленную задачу. В результате синтеза нейросетевого регулятора NARMA-L2 Controller было установлено, что для решения поставленной задачи количество нейронов находится в пределах $S = 8...10$. Оптимальные значения дискретности установлены в пределах $\Delta t = 0.1...0.25$. Оптимальные значения в решаемой задаче находятся в пределах $N_B = 1000...2500$.

В результате проведенных исследований были установлены оптимальные параметры NARMA-L2 Controller, которые соответствуют вариантам $a-g$ в табл. 1.

В табл. 2 представлен сравнительный анализ показателей качества обучения нейросетевого регулятора NARMA-L2 Controller при различных алгоритмах обучения. Исследование показало, что алгоритм Левенберга–Марквардта наиболее эффективен для обучения данного нейросетевого регулятора.

На рис. 8 представлены переходные процессы по скорости линейного движения v , м/с суппорта токарного станка, которые соответствуют вариантам $a-g$ табл. 1. Исследование показало,

что для обеспечения хороших динамических характеристик и повышения точности перемещения суппорта с заданной траекторией, а также для компенсации упругих колебаний можно использовать NARMA-L2 Controller в качестве регулятора положения в следящем электроприводе подачи токарного станка. Как видно из приведенных переходных процессов, по скорости линейного перемещения суппорта вариант рис. 8, б имеет высокую динамическую характеристику.

Таким образом, был выполнен синтез нейрорегулятора NARMA-L2 Controller для стабилизации скорости линейного движения суппорта и компенсации колебаний, возникающих в упругих элементах приводов подачи токарных станков. Разработана модель статической сети с прямой передачей сигнала нейросетевого регулятора NARMA-L2 Controller. Для поиска оптимальных параметров регулятора было проведено несколько вариантов синтеза нейроконтроллера с разными алгоритмами обучения. Результаты моделирования показали, что при обучении нейрорегулятора NARMA-L2 Controller алгоритм Левенберга–Марквардта по сравнению с другими алгоритмами наиболее эффективный и быстродействующий. С помощью варьирования параметры нейрорегулятора NARMA-L2 Controller было установлено, какие параметры существенно влияют на качество регулирования.

СПИСОК ЛИТЕРАТУРЫ

1. Оськин Д. А., Дыда А. А. Нейросетевое прогнозирующее управление приводом робота на базе двухмассовой модели с упругостью // *Фундаментальные исследования*. 2015. № 11 (Ч. 5). С. 909–913.
2. Бураков М. В. Нейронные сети и нейроконтроллеры: учеб. пособие. ГУАП. СПб., 2013.
3. Фираго Б. И., Павлячик Л. Б. Теория электропривода: учеб. пособие. 2-е изд. Минск: Техноперспектива, 2007.

4. Белов М. П., Носиров И. С., Фьонг Х. Ч. Исследование системы управления электроприводом подачи токарного станка с применением метода обобщенного нейроуправления с прогнозированием // *Изв. СПбГЭТУ «ЛЭТИ»*. 2018. № 4. С. 73–80.
5. Медведев В. С., Потемкин В. Г. Нейронные сети. MATLAB 6 / под общ. ред. канд. техн. наук В. Г. Потемкина. М.: ДИАЛОГ-МИФИ, 2002.

M. P. Belov, I. S. Nosirov, A. M. Belov
Saint Petersburg Electrotechnical University «LETI»

SYNTHESIS NEURAL NETWORK CONTROLLER FOR TWO-MASS ELECTROMECHANICAL SYSTEM OF LATHE MACHINE'S FEED DRIVE

The analyses of the advantage and disadvantage of the Neural Network Predictive Controller implemented in the Neural Network Toolbox are considered. A mathematical description of two-mass electromechanical drive system for lathe machine feed drive with elastic connections. During synthesis procedure, the neural regulator for stabilizing the speed of linear motion and compensation vibration occurring in the elastic elements of lathe machine's feed drive is proposed. In this article several algorithms as Moller, Levenberg–Marquardt, Sheld–Ribira, gradient descent for training the neural regulator NARMA-L2 Controller are compared. The parameters of neural regulator NARMA-L2 have significantly affected the quality of control system. The comparative analysis of the quality indicators of the training of the neural network controller under various learning algorithms is given. It is shown that the use of the NARMA-L2 Controller neural network controller makes it possible to improve the quality of the control system (CS) parameters of the lathe machine's feed drive.

Electromechanical system, lathe machine feed drive with elastic connections, neuroregulator, Levenberg–Marquardt learning algorithm