



УДК 62-83 + 520.27

М. П. Белов, Ч. Х. Фыонг

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

Н. К. Чыонг

Научно-исследовательский институт Viettel (Вьетнам)

Разработка рекуррентных нейронных сетей в задачах идентификации систем управления следящими электроприводами крупного радиотелескопа

Предлагается применение нейросетевой идентификации систем управления в задачах прогнозирования углового азимутального поворота главного зеркала крупного радиотелескопа. Описывается способ построения структуры рекуррентных нейронных сетей, основанных на «моделях нелинейной авторегрессии с экзогенными входами – модели NARX» в форме пространства состояний, что делает их удобными устройствами в таких областях, как нелинейное прогнозирование и моделирование. Для обучения рекуррентных нейронных сетей рассматриваются 3 алгоритма: классический алгоритм обратного распространения во времени, байесовская регуляризация и алгоритм оптимизации Левенберга-Марквардта. Эти алгоритмы представляют собой расширение стандартного алгоритма обратного распространения и позволяют градиентным спускам значительно быстрее сходиться и лучше обобщаться. При компьютерном моделировании сравнивалось качество работы нейросетевой идентификационной модели с разными параметрами в системах управления следящими электроприводами крупного радиотелескопа. Ее качество работы зависит от значения горизонта прогноза регулятора MPC-Лагерра, размера слоя, функции обучения и глубины единичных задержек. Построение, обучение, тестирование нейронных сетей производится с помощью программы MATLAB/Simulink.

Крупный радиотелескоп, идентификация, рекуррентные нейронные сети, модели NARX, следящий электропривод

Идентификация систем управления (СУ) – это экспериментальный подход к моделированию процессов или производств с неизвестными параметрами. С исторической точки зрения до 1980-х гг. идентификация СУ использовала линейные параметрические авторегрессивные модели (linear parametric Auto Regression – AR), скользящие средние модели (Moving Average – MA) и авторегрессивные скользящие средние модели (Autoregressive Moving Average – ARMA), введенные Дж. Боксом и Г. Дженкинсом [1]. Поскольку эти модели линейные, они не способны справляться с некоторыми нестационарными сигналами и сигналами, математическая модель которых не линейная.

Главной задачей идентификации СУ служит нахождение идентификационной модели $\hat{F}(\mathbf{u})$, достаточно близкой к объекту управления $F(\mathbf{u})$ для всех $\mathbf{u}(k)$, $k = 1, 2, \dots, N$ (рис. 1)

$$\|\mathbf{y} - \hat{\mathbf{y}}\| = \|F(\mathbf{u}) - \hat{F}(\mathbf{u})\| \leq \epsilon, \quad (1)$$

где ϵ – малое положительное число или среднеквадратичное отклонение ошибки (СКО), определенное нормой $\|\cdot\|$; $\hat{\mathbf{y}} = \hat{F}(\mathbf{u})$ – выход идентификационной модели; $\mathbf{u}(k)$ – допустимое множество управления. Причем для статической или динамической системы идентификационная модель $\hat{F}(\mathbf{u})$ определена парами векторов сигналов вход-

выход $\{u(k), y(k)\}$. Выбор идентификационной модели $\hat{F}(u)$ по (1) зависит от имеющейся априорной информации о структуре объекта управления. Выбор класса, которому принадлежит идентификационная модель $\hat{F}(u)$, определяется множеством факторов, связанных с требуемой точностью и аналитической трактуемостью модели.

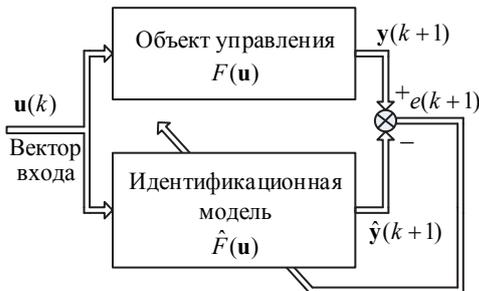


Рис. 1

Модели рекуррентных нейронных сетей.

В последние годы нейронные сети (НС) служат мощным математическим вычислительным инструментом, хорошо подходящим для управления техническими объектами, решения и обработки широкого класса задач – идентификации, прогнозирования, распознавания образов, аппроксимации данных в системах управления и пр. История теории НС не нова: они постепенно развивались с 1950-х гг., но в течение последних двух десятилетий в связи с развитием современных вычислений, а также с очень быстрым развитием технологии системной интеграции была ускорена эволюция нейронных сетей. НС теперь занимают важное место в области СУ в целом и управления следящими электроприводами сложных объектов в частности. По сравнению с традиционными математическими методами НС имеют выдающиеся преимущества [2], [3]:

- 1) возможность параллельных вычислений информации всеми звеньями при практической реализации;
- 2) возможность находить неизвестные отображения взаимосвязи между выходными и входными сигналами при помощи алгоритма обучения;
- 3) возможность аппроксимировать произвольные нелинейные динамические объекты;
- 4) приобретение сетью устойчивости к ошибкам при большом числе межнейронных соединений;
- 5) интеллект и способность к самоорганизации;
- 6) отказоустойчивость.

В нейронной сети за единицу обработки информации принят нейрон. На рис. 2 показан общий вид детализированной модели нейрона, лежащего в основе НС.

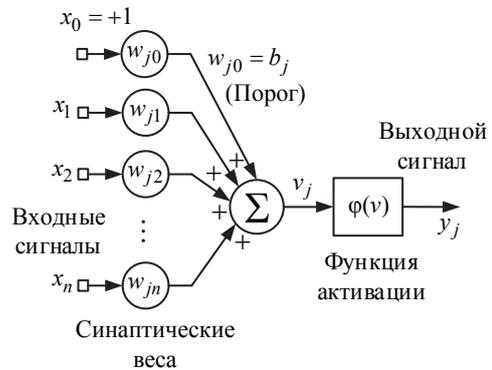


Рис. 2

Математическое описание модели нейрона по формуле Мак-Калока–Питтса [2] может быть записано в виде

$$y_j = \varphi \left(\sum_{i=1}^n x_i w_{ji} + b_j \right), \quad (2)$$

где $\varphi(v)$ – активационная функция; x_1, x_2, \dots, x_n – входные сигналы нейрона; y_j – выходной сигнал нейрона; $w_{j1}, w_{j2}, \dots, w_{jn}$ – синаптические веса нейрона j ; b_j – пороговое значение.

В (2) добавился новый синапс. Его входной сигнал $x_0 = +1$, а вес $w_{j0} = b_j$. В результате введения порога добавляется новый входной сигнал фиксированной величины +1, а также появляется новый синаптический вес, равный пороговому значению b_j . Можно переписать (2) в форме

$$y_j = \varphi \left(\sum_{i=0}^n x_i w_{ji} \right)$$

или в векторном форме

$$y_j = \varphi(\mathbf{xw}_j^T).$$

Здесь $\mathbf{x} = [1, x_1, x_2, \dots, x_n]^T$ – вектор входных сигналов; $\mathbf{w}_j = [w_{j0}, w_{j1}, \dots, w_{jn}]^T$ – вектор синаптических весов нейрона j .

Активационная функция, представленная в формуле как $\varphi(v)$, выражает выходной сигнал нейрона в зависимости от индуцированного локального поля v_j . В настоящее время используется множество преобразований, некоторые из которых показаны в табл. 1.

Таблица 1

| Тип функции | Функция |
|-------------------------|--|
| Ступенчатая Хэвисайда | $\varphi(v) = \begin{cases} 1, & \text{если } v \geq 0; \\ 0, & \text{если } v < 0 \end{cases}$ |
| Кусочно-линейная | $\varphi(v) = \begin{cases} 1, & \text{если } v \geq 1/2; \\ v , & \text{если } -1/2 < v < 1/2; \\ 0, & \text{если } v \leq -1/2 \end{cases}$ |
| Сигмоидальная | $\varphi(v) = (1 + e^{-av})^{-1}$ |
| Гиперболический тангенс | $\varphi(v) = \text{th } v$ |
| Логарифмическая | $\varphi(v) = \ln(v + \sqrt{v^2 + 1})$ |

НС представляют собой совокупность большого числа сравнительно простых элементов – нейронов, топология соединений которых зависит от типа сети. Часть нейронов связаны с «внешним миром», а какие-то – только с другими нейронами (скрытые нейроны). НС могут быть классифицированы в три основные структуры, а именно: 1) однослойные сети с прямой связью (single-layer feedforward networks); 2) многослойные сети с прямой связью (multi-layer feedforward networks); 3) сети с обратной связью, или рекуррентные нейронные сети (recurrent networks).

Выбор структуры НС зависит от особенностей и сложностей задачи. Благодаря возможности аппроксимировать произвольные объекты НС представляют собой современный метод для решения задач идентификации нелинейных статических и динамических СУ. На сегодняшний день наблюдается возрождение в области идентификации динамических СУ с рекуррентными нейронными сетями, когда становится ясно, что этот тип идентификации представляет подходящее приложение для оценки (прогнозирования) выходных значений в будущем. Показано, что рекуррентные нейронные сети с достаточно большим числом нейронов служат реализацией нелинейного авторегрессивного скользящего среднего процесса (Nonlinear Autoregressive Moving Average – NARMA) [1], [4], [5].

В данной статье архитектурный подход, предложенный для решения идентификации СУ, основан на «моделях нелинейной авторегрессии с экзогенными входами» (Nonlinear Autoregressive with Exogenous inputs), которые называются рекуррентными нейронными сетями NARX или моделями NARX [3], [4]. Это мощный класс моделей, которые хорошо подходят для моделирования нелинейных систем. Одним из основных применений динамических нейронных сетей NARX является система управления.

Архитектурное строение рекуррентных нейронных сетей может принимать множество различных форм, но наиболее простые используют архитектурные нейронные сети с обратными связями. Эта модель имеет единственный вход, который применяется к памяти на линиях задержки, состоящей из d_u элементов, и единственный выход, замкнутый на вход через память на линиях задержки, которые также содержат элементы d_y . Содержимое этих двух блоков памяти используется для питания входного слоя персептрона.

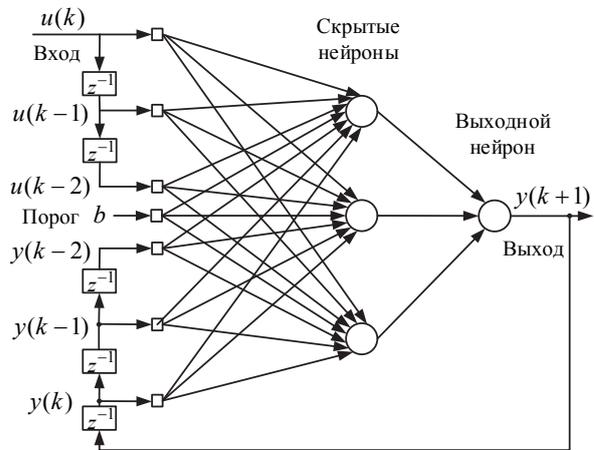


Рис. 3

На рис. 3 показана архитектура обобщенной рекуррентной сети, построенной на базе многослойного персептрона с одним скрытым слоем $d_u = d_y = 2$. Вход модели обозначается как $u(k)$, а соответствующий выход – как $y(k+1)$. Это значит, что выход модели опережает ее вход на одну единицу времени. Вектор сигнала, подаваемый на вход персептрона, состоит из следующих элементов:

- текущее и предыдущее значения входного управляющего сигнала: $u(k), u(k-1), \dots, u(k-d_u)$, представляющие сети, которые имеют внешнее происхождение;

- значения выходного сигнала $y(k), y(k-1), \dots, y(k-d_y)$ в предшествующие моменты времени, от которых зависит выход модели $y(k+1)$.

Таким образом, динамика модели NARX описывается следующим нелинейным уравнением:

$$y(k+1) = \varphi\{u(k), u(k-1), \dots, u(k-d_u), y(k), y(k-1), \dots, y(k-d_y)\}. \quad (3)$$

Кроме того, применение обратных связей позволяет использовать описание рекуррентных нейронных сетей NARX в виде множества состояний, что делает их удобными устройствами в нелинейном прогнозировании и моделировании [3]. На рис. 4 показана блочная диаграмма модели NARX в пространстве состояний, описанная в работе Элмана [6].

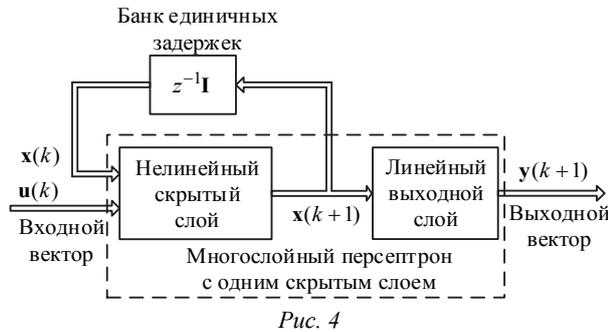


Рис. 4

Сеть Элмана содержит рекуррентные связи скрытых нейронов со слоем контекстных элементов, состоящих из единичных задержек. Эти контекстные элементы сохраняют выходы скрытых нейронов на один шаг времени, после чего передают их на входной слой. Таким образом, скрытые нейроны записывают свои предыдущие действия, что позволяет реализовать задачи обучения, разворачивающиеся во времени. Скрытые нейроны также передают информацию выходным нейронам, которые формируют реакцию сети на примененное извне возмущение. Поскольку данная природа обратной связи связана исключительно со скрытыми нейронами, они могут распространять повторные циклы информации по сети на протяжении множества шагов времени и таким образом открывать доступ к абстрактному представлению времени.

Пусть вектор $\mathbf{u}(k)$ размером $m \times 1$ обозначает входной сигнал в момент времени k ; вектор $\mathbf{x}(k)$ размером $q \times 1$ – состояние нелинейной системы дискретного времени; вектор $\mathbf{y}(k)$ размером $p \times 1$ – соответствующий выход системы. Тогда динамика модели NARX (3) описывается следующей нелинейной системой:

$$\begin{cases} \mathbf{x}(k+1) = \varphi(W_a \mathbf{x}(k), W_b \mathbf{u}(k)); \\ \mathbf{y}(k) = C \mathbf{x}(k), \end{cases} \quad (4)$$

где W_a – $(q \times q)$ -матрица; W_b – $(q \times (m+1))$ -матрица; C – $(p \times q)$ -матрица; $\varphi(\cdot)$ – диагональная матрица активационных функций вида

$$\varphi : \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_q \end{bmatrix} \rightarrow \begin{bmatrix} \varphi(x_1) \\ \varphi(x_2) \\ \dots \\ \varphi(x_q) \end{bmatrix}. \quad (5)$$

Можно описать интерпретацию матриц W_a , W_b , C , а также нелинейных активационных функций $\varphi(\cdot)$ следующим образом:

- матрица W_a содержит синаптические веса q нелинейных нейронов скрытого слоя, соединяющиеся с узлами обратной связи входного слоя;
- матрица W_b содержит синаптические веса q нелинейных нейронов скрытого слоя, соединяющиеся с узлами источника входного слоя;
- матрица C включает в себя синаптические веса p линейных нейронов выходного слоя, соединяющие их со скрытыми нейронами;
- активационные функции (5) представляют собой сигмоидальные функции активации скрытых нейронов слоя. Они обозначаются функцией гиперболического тангенса

$$\varphi(x) = \text{th } x = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

или логистической функцией

$$\varphi(x) = \frac{1}{1 + e^{-x}}.$$

Важное свойство рекуррентных нейронных сетей NARX, описываемых моделью в пространстве состояний (4), – то, что они могут аппроксимировать достаточно широкий класс нелинейных динамических систем. Однако эта аппроксимация достоверна только на компактных подмножествах состояний пространства и на конечных интервалах времени и не отражает некоторые интересные динамические характеристики.

Теперь обратимся к вопросу обучения рекуррентных нейронных сетей. К задаче обучения НС модели NARX относятся трудности с настройкой весов нейронов, которые могут быть реализованы с помощью специального алгоритма. Данный алгоритм обучения называется обобщенным дельта-правилом или правилом обратного распространения ошибки [2]. Алгоритм обратного распространения ошибки обучает НС, вычисляя целевую функцию ошибки для сигнального входа с дальнейшим ее обратным распространением от каждого последующего слоя к предыдущему.

По методу наименьших квадратов минимизируемая целевая функция ошибки НС $E(w)$ записывается следующим образом:

$$E(w) = \frac{1}{2} \sum_{j=1}^N e_j^2(k), \quad (6)$$

где j – индекс выходного нейрона; $e_j(k)$ – сигнал ошибки между желаемым значением выходного нейрона j и его реальным значением на итерации k .

Суммирование осуществляется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация целевой функции (6) может реализоваться методом градиентного спуска, что означает подстройку весовых коэффициентов:

$$\Delta w_{ji}^{(n)}(k) = -\eta \frac{\partial E(w)}{\partial w_{ji}(k)}.$$

Здесь $\Delta w_{ji}^{(n)}(k)$ – подстройка весового коэффициента синаптической связи, соединяющей нейрон i в слое $(n - 1)$ с нейроном j в слое n на итерации k ; $\frac{\partial E(w)}{\partial w_{ji}(k)}$ – вектор частных производных целевой функции $E(w)$ по свободным параметрам сети; $0 < \eta < 1$ – параметр скорости обучения.

Выбранный метод обучения в этой работе использует алгоритм обратного распространения во времени (backpropagation through time algorithm). Он служит расширением стандартного алгоритма обратного распространения и может быть получен с помощью развертывания временных операций в многослойной сети прямого распространения, топология которой расширяется на один слой для каждого шага времени. Алгоритм обратного распространения во времени имеет ряд общих характеристик. Во-первых, он основан на методе градиентного спуска, тогда как мгновенное значение функции стоимости минимизируется по синаптическим весам сети. Во-вторых, этот метод довольно прост в реализации, но может медленно сходиться. В-третьих, функция сетевого обучения, которая обновляет значения веса и смещения в соответствии с оптимизацией Левенберга–Марквардта (Levenberg–Marquardt), была изменена, чтобы включить метод регуляризации. Он минимизирует комбинацию квадратов ошибок и весов и затем определяет правильную комбинацию, чтобы создать сеть, которая хорошо обобщается. Этот процесс называется байесовской регуляризацией (Bayesian).

Если в задачах идентификации СУ рекуррентные нейронные сети содержат до нескольких сотен весов, то алгоритм Левенберга–Марквардта будет иметь самую быструю сходимость. Это преимущество особенно заметно, если требуется очень точная подготовка. Однако по мере увеличения количества весов в сети преимущество этого алгоритма уменьшается.

Сообщалось о некоторых важных качествах рекуррентных нейронных сетей NARX с алгоритмом обучения Левенберга–Марквардта: 1) обучение более эффективно в сетях NARX, чем в других нейронных сетях (градиентный спуск лучше в сетях NARX); 2) эти сети намного быстрее сходятся и лучше обобщаются, чем другие сети [4].

Нейросетевая идентификация на основе моделей NARX. Рассмотрим СУ с одним входом и одним выходом на рис. 5. Пусть выход системы в дискретный момент времени k обозначается как $y(k)$, а ее вход – как $u(k)$. Тогда при выборе для работы модели NARX прогнозируемый выход нейросетевой идентификации будет записываться формулой

$$\hat{y}(k+1) = \hat{F}\{u(k), u(k-1), \dots, u(k-d_u), y(k), y(k-1), \dots, y(k-d_y)\},$$

где выход модели идентификации $\hat{y}(k+1)$ представляет собой оценку выхода объекта $y(k+1)$. Оценка $\hat{y}(k+1)$ вычитается из сигнала $y(k+1)$. По (1) получается сигнал ошибки

$$e(k+1) = y(k+1) - \hat{y}(k+1).$$

Здесь величина $y(k+1)$ играет роль желаемого отклика. Ошибка $e(k+1)$ используется для коррекции синаптических весов нейронной сети

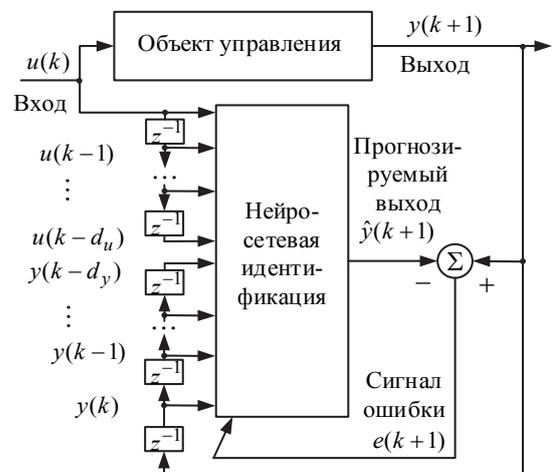


Рис. 5

для минимизации ошибки, основанной на критерии среднеквадратической ошибки.

Решение NARX задачи системной идентификации (рис. 5) представлено в последовательно-параллельной форме, так как выходной сигнал объекта управления (а не выход модели идентификации) замкнут на вход модели.

Компьютерные эксперименты. Рассмотрим пример применения моделей NARX для настройки идентификационной модели управляемого объекта, чтобы прогнозировать угловой азимутальный поворот главной антенны (φ_3) в системе управления следящими электроприводами крупного радиотелескопа РТ-70 [7]. В [8] была предложена математическая расширенная модель автоматизированных систем управления электроприводами (АСУ ЭП) наведения крупного радиотелескопа, эквивалентная разветвленной четырехмассовой упругой системе в матричном виде

$$\begin{cases} \mathbf{x}(k+1) = A\mathbf{x}(k) + B\mathbf{u}(k); \\ \mathbf{y}(k) = C\mathbf{x}(k) \end{cases} \quad (7)$$

с координатами

$$\mathbf{x}(k) = [\omega_1 \quad M_{21} \quad \omega_2 \quad M_{32} \quad \omega_3 \quad M_{42} \quad \omega_4 \quad i_d \quad \varphi_3]^T;$$

$$A = \begin{bmatrix} -J_{13}^{-1}b_{213} & -J_1^{-1} & J_1^{-1}b_{213} & 0 & 0 & 0 & 0 & J_1^{-1} & 0 \\ c_{213} & 0 & -c_{213} & 0 & 0 & 0 & 0 & 0 & 0 \\ J_2^{-1}b_{213} & J_2^{-1} & -J_2^{-1}b_3 & -J_2^{-1} & J_2^{-1}b_{32} & -J_2^{-1} & J_2^{-1}b_{42} & 0 & 0 \\ 0 & 0 & c_{32} & 0 & -c_{32} & 0 & 0 & 0 & 0 \\ 0 & 0 & J_3^{-1}b_{32} & J_3^{-1} & -J_3^{-1}b_{32} & 0 & 0 & 0 & 0 \\ 0 & 0 & c_{42} & 0 & 0 & 0 & -c_{42} & 0 & 0 \\ 0 & 0 & J_4^{-1}b_{42} & 0 & 0 & 0 & -J_4^{-1}b_{42} & 0 & 0 \\ K_i T_i^{-1} & 0 & 0 & 0 & 0 & 0 & -K_i T_i^{-1} & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix};$$

$$B = [0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad K_i T_i^{-1} \quad 0]^T;$$

$$C = [0 \quad 0 \quad 1];$$

$$b_3 = b_{213} + b_{32} + b_{42},$$

где первая масса – двигатель (J_{13}), двухдвигательный привод заменен на эквивалентный однодвигательный; вторая – платформа (J_2), на которой смонтирован угломестный привод; третья – зеркальная часть (J_3); четвертая – противовесы (J_4), уравновешивающие зеркало при перемеще-

нии его по углу места; ω_1 – ω_4 – скорости каждой массы; $M_d, M_{21}, M_{32}, M_{42}$ – момент двигателя и моменты упругих связей между массами; b_{213}, b_{32}, b_{42} – коэффициенты внутреннего трения; c_{213}, c_{32}, c_{42} – коэффициенты жесткости механической части; i_d – ток двигателя; $\mathbf{y}(k) = \varphi_3$ – вектор выхода угла азимутального поворота главной антенны. В контуре положения АСУ ЭП наведения крупного радиотелескопа РТ-70 лежит прогнозирующий цифровой регулятор, основанный на функциях Лагерра (MPC-Лагерра). Структурная схема модели АСУ ЭП объекта показана на рис. 6, и его параметры подробно представлены в [8].

Эта структура включает блок управляемого объекта (Discrete State Space Plant), блок регулятора с предсказанием (MPC-Laguerre Predictive Controller) и блок нейросетевой идентификации на основе моделей NARX (NARX Neural Network – NNET), а также построения графиков (Graph).

Блок НС NARX идентификационной модели, реализованный в пакете Neural Network Time Series Tool, имеет два слоя. Первый слой – скрытый с сигмоидальными функциями активации в виде гиперболического тангенса, второй – выходной с

тождественными функциями активации. Вектор входных сигналов включает в себя единичные задержки $d_u = d_y = d$, отсчитываемые от того момента времени, для которого делается прогноз. Данная НС – статическая. Общий вид модели НС NARX в пакете Neural Network Time Series Tool представлен на рис. 7.

Формирование множества векторов для обучения происходит следующим образом. Рассматриваются различные комбинации величин, харак-

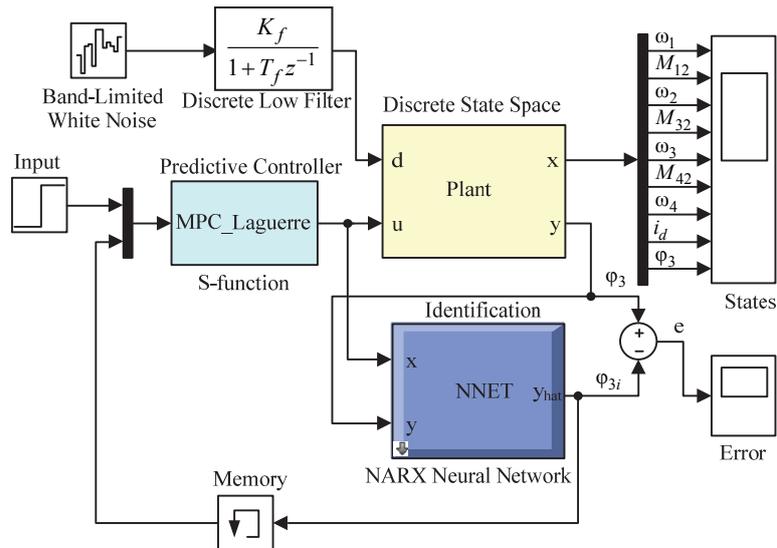


Рис. 6

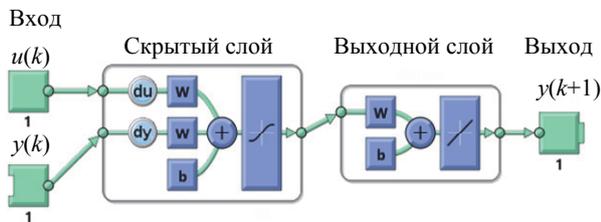


Рис. 7

теризующих управляющие воздействия, φ_3 – угол азимутального поворота главной антенны и внешние возмущающие воздействия типа белого шума. Угол азимутального поворота главной антенны варьируется в диапазоне от 0 до 36 000'' с дискретностью 2''. Длительность моделирования составляет 30 мин. В качестве внешних возмущений учитывается ветер, влияющий на динамику АСУ ЭП крупного радиотелескопа. Ветровой поток со средней скоростью ветра предполагается равным 10 м/с. Амплитуда внешнего возмущающего воздействия была взята равной 10 % от максимальной величины полезного сигнала. Количество образцов для обучения НС составляет 180 000. Эксперименты выполнялись с помощью программы MATLAB/Simulink R2016a с периодом дискретности $T_s = 10^{-2}$ с. Ступенчатое управляющее воздействие равно $\varphi_{\Pi} = 20''$.

Для исследования влияний параметров нейросетевой идентификации на АСУ ЭП наведения крупного радиотелескопа воспользуемся различными настройками ее параметров и будем менять:

- 1) горизонт прогноза MPC-Лагерра регулятора, N_p ;
- 2) обучающую функцию;
- 3) размер скрытого слоя, который определяется количеством используемых нейронов;
- 4) глубину единичных задержек, $d_u = d_y = d$.

В первую очередь выберем три значения горизонта прогноза MPC-Лагерра регулятора и исследуем в отдельности каждое значение:

- 1) $N_p = 30$; 2) $N_p = 106$; 3) $N_p = 68$.

Затем в настройках нейросетевой идентификации выберем три функции обучения и исследуем в отдельности каждую:

- 1) `traindgm` – классический алгоритм обратного распространения во времени;
- 2) `trainbr` – байесовская регуляризация;
- 3) `trainlm` – алгоритм оптимизации Левенберга–Марквардта.

Далее будем задавать разный размер скрытого слоя, который определяется количеством используемых нейронов:

- 1) 2 нейрона в первом (скрытом) слое, 1 нейрон во втором (выходном) слое;
- 2) 4 нейрона в скрытом слое, 1 нейрон в выходном слое;
- 3) 10 нейронов в скрытом слое, 1 нейрон в выходном слое.

И, наконец, выберем три значения глубины единичных задержек d :

- 1) при $d = 1$ модель НС описывается в виде

$$\hat{y}(k+1) = \hat{F}\{u(k), u(k-1), \varphi_3(k), \varphi_3(k-1)\};$$

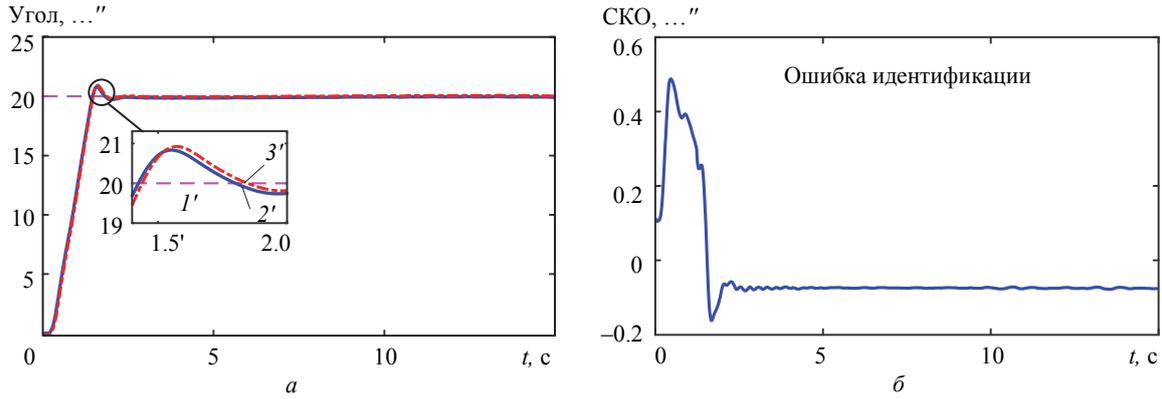


Рис. 8

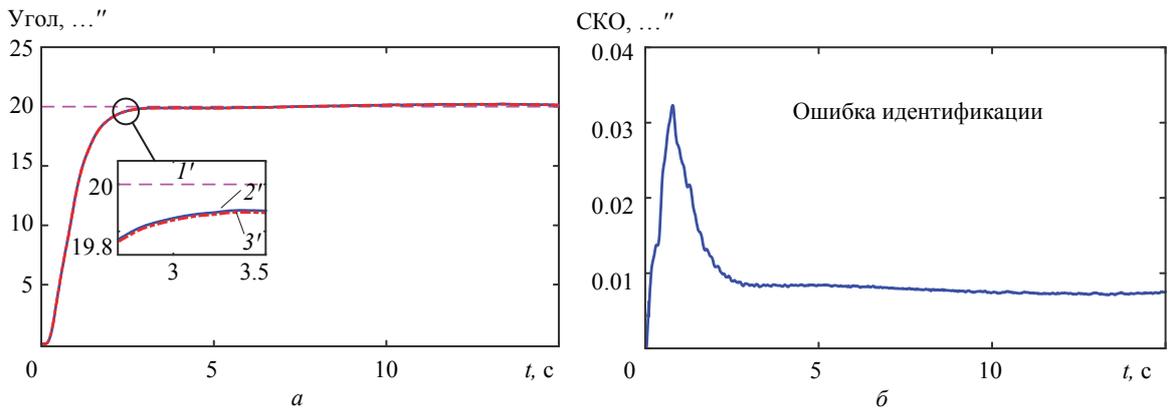


Рис. 9

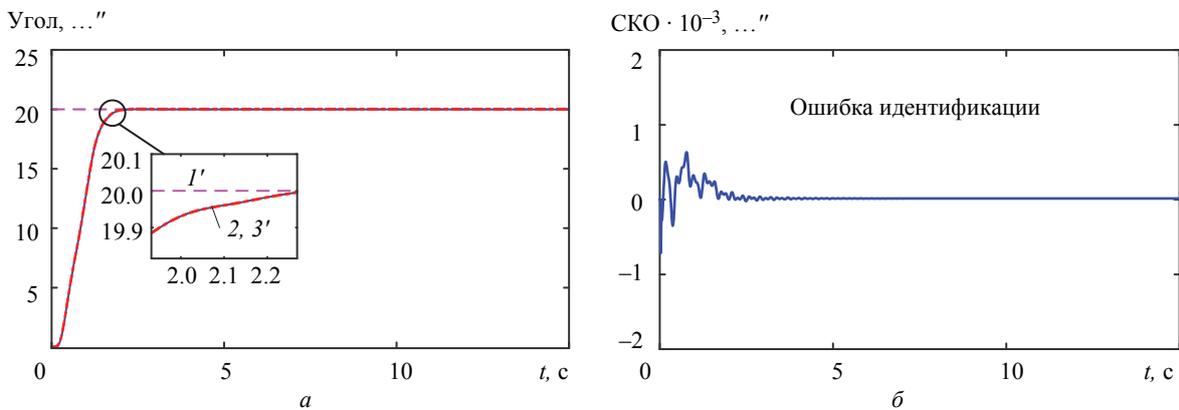


Рис. 10

2) при $d = 2$ модель НС описывается в виде

$$\hat{y}(k+1) = \hat{F}\{u(k), u(k-1), u(k-2), \varphi_3(k), \varphi_3(k-1), \varphi_3(k-2)\};$$

3) при $d = 3$ модель НС описывается в виде

$$\hat{y}(k+1) = \hat{F}\{u(k), u(k-1), u(k-2), u(k-3), \varphi_3(k), \varphi_3(k-1), \varphi_3(k-2), \varphi_3(k-3)\}.$$

В результате получим графики переходного процесса угла азимутального поворота главного зеркала и графики СКО по углу идентификации между реакциями процесса и идентификацион-

ными моделями $e = \varphi_3 - \varphi_{3и}$, где рис. 8–10 – первый–третий варианты эксперимента. Результаты показаны в табл. 2. На рис. 8–10 показаны кривые: 1 – $\varphi_{п}$; 2 – φ_3 ; 3 – $\varphi_{3и}$.

Таблица 2

| Параметр | Вариант | | |
|------------------------|---------|-------|---------------------|
| | 1 | 2 | 3 |
| Время нарастания, с | 1.6 | 2.78 | 1.72 |
| Время регулирования, с | 1.82 | 4.1 | 2.86 |
| Перерегулирование, % | 8.2 | 2 | 0 |
| СКО, ..." | 0.15 | 0.012 | $0.2 \cdot 10^{-3}$ |

В зависимости от значения горизонта прогноза регулятора MPC-Лагерра, размера слоя, функции обучения нейронной сети и глубины единичных задержек получены различные графики переходного процесса и определены ошибки по углу для трех вариантов. Варьируя параметры настройки нейросетевой идентификационной модели, можно подобрать оптимальный вариант для системы управления, что приведет к наиболее качественной работе всей системы. Как видно из табл. 2 и рис. 8–10, малое СКО третьего варианта имеет наименьшее значение $(0.2 \cdot 10^{-3})''$ по сравнению с другими вариантами. Это означает, что алгоритм обучения Левенберга–Марквардта с достаточно большим числом нейронов является одним из самых эффективных методов для построения нейросетевой иденти-

фикации и обеспечивает плавное перемещение объекта управления.

Таким образом, были выполнены несколько эффективных сценариев настройки идентификационной модели СУ в задачах прогнозирования углового азимутального поворота главного зеркала крупного радиотелескопа с использованием рекуррентной нейронной сети NARX. Разные варианты настроек идентификационной модели сравнивались с целью их применения в системах управления следящих электроприводах сложных объектов. Результаты данной работы также показывают, что рекуррентные нейронные сети NARX могут применяться в задачах идентификации систем управления следящими электроприводами многомассовых систем с упругими передачами.

СПИСОК ЛИТЕРАТУРЫ

1. Семенов А. Д., Артамонов Д. В., Брюхачев А. В. Идентификация объектов управления: учеб. пособие. Пенза: Изд-во Пенз. гос. ун-та, 2003. 211 с.
2. Борцов Ю. А., Соколовский Г. Г. Автоматизированный электропривод с упругими связями. СПб.: Энергоатомиздат, 1992. 288 с.
3. Белов М. П. Современные подходы к структурно-параметрическому синтезу, исследованию и управлению автоматизированными электроприводами промышленных агрегатов. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2012. 206 с.
4. Diaconescu E. The use of NARX neural networks to predict chaotic time series // WSEAS Trans. Comp. Research. 2008. Vol. 3. P. 182–191.
5. Narendra K. S., Parthasarthy K. Identification and control of dynamical systems using neural networks // IEEE Trans. Neural networks. 1990. Vol. 1. P. 4–26.
6. Elman J. L. Finding structure in time // Cogn. Sci. 1990. Vol. 14. P. 179–211.
7. Хайкин С. Нейронные сети: полный курс / пер. с англ. М.: Вильямс, 2006. 1102 с.
8. Tran Huu Phuong, Belov M. P., Tran Dang Khoa. Model predictive controller based on Laguerre functions for large radio telescope servo control system // In 2018 IEEE NW Russia Young Researchers in Electrical and Electronic Engin. Conf. (ElConRusNW). M., 2018. P. 1020–1024.

M. P. Belov, T. H. Phuong
Saint Petersburg Electrotechnical University «LETI»

N. C. Truong
Viettel Research and Development Institute (Vietnam)

IDENTIFICATION CONTROL SYSTEM BASED RECURRENT NEURAL NETWORKS FOR LARGE RADIO TELESCOPE SERVO DRIVE

The identification model control system using artificial neural networks to estimate the angle main mirror in azimuth moving of large radio telescope electrical servo drive is proposed. An architectural approach to design recurrent neural networks based on «Nonlinear Auto Regressive with Exogenous inputs – NARX models» in form of the state space is analyzed in this paper. It is convenient to application this design in the field of nonlinear prediction and modeling. The dynamic back-propagation algorithm through time, Bayesian regularization and Levenberg–Marquardt optimization algorithm are proposed for training purposes. These algorithms are extensions of the standard back-propagation algorithm and allow compute the gradients to converge much faster and better than the standard ones. During computer simulation, the performances of neural network identification model with different parameters are compared in the working of electric drives control systems of large radio telescope. Its performances depend on the value of the forecast horizon MPC-Laguerre regulator, the size of the layer, the training function and the length of tapped delays line of neural networks. In this work, designing, training, testing of neural networks identification model are implemented on Matlab/SIMULINK environment.

Large radio telescope, system identification, recurrent neural networks, NARX models, servo drive system