

УДК 62-83 + 681.513.3

М. П. Белов, Н. В. Лань

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

Разработка нейросетевого наблюдателя для оценки координат системы управления электроприводом оптико-механического комплекса

Предложено применение рекуррентной нейронной сети в качестве нейросетевого наблюдателя состояния для восстановления электромеханических переменных координат в системе управления следящим электроприводом наведения оптико-механического комплекса. Разрабатывается математическое описание электропривода оптико-механического комплекса в виде двухмассовой системы с упругими связями. Данные упругие колебания двухмассовой системы компенсируются с помощью дополнительных сигналов обратной связи от оценки упругого момента и скорости нагрузки, полученной при использовании нейросетевого наблюдателя состояния. Проведен анализ архитектур динамических рекуррентных нейронных сетей по схеме Элмана в форме векторно-матричной модели, позволяющий аппроксимировать широкий спектр нелинейных динамических систем. С помощью имитационного моделирования в программной среде MatLab/Simulink проведено сравнение среднеквадратической ошибки между различными алгоритмами обучения рекуррентных нейронных сетей Элмана с целью исследования их по точности оценки координат в замкнутом контуре системы управления электроприводом оптико-механического комплекса.

Оптико-механический комплекс, рекуррентные нейронные сети Элмана, нейросетевой наблюдатель состояния, двухмассовая упругая система

Вопросы повышения качества регулирования системы управления следящими электроприводами (СЭП) наведения оптико-механических комплексов (ОМК) представляют собой актуальные научно-исследовательские задачи. Их решение требует исследования свойств многомассовых механизмов исполнительных осей ОМК как элементов электромеханических систем с нелинейными упругими свойствами. Влияние упругих колебаний негативно сказывается на точности, качестве регулирования и стабилизации углового положения ОМК. К известным способам демпфирования влияния упругих колебаний на динамику СЭП наведения ОМК относится синтез законов управления, использующих информацию о координатах упругих колебаний. Однако измерение всех упругих колебаний переменных состояния не всегда возможно, и тогда целесообразно построение систем управления СЭП ОМК с использованием наблюдателя переменных состояния [1]–[3].

В [4]–[5] оптимальные наблюдатели на основе фильтра Калмана были применены для восстановления неизмеряемых переменных состояния.

Наблюдатели для линейной системы с неизменяемыми параметрами и малым значением шума измерения могут гарантировать хорошую точность оцененных переменных состояния. Однако оптимальный наблюдатель Калмана имеет некоторые недостатки: для обеспечения его точной работы необходимо правильно задать матрицы состояния и ковариации измерений, что непросто. Кроме того, алгоритм Калмана сложен для синтеза и требует быстродействующего микропроцессора, который, в свою очередь, увеличивает общую стоимость приложения.

В последние годы в промышленных приложениях набирают популярность рекуррентные нейронные сети (РНС). Они применяются в различных отраслях промышленности, включая системы следящих электроприводов для оценки переменных состояния, управления и диагностики [6]–[8]. По сравнению с традиционными методами РНС имеют преимущество – возможность аппроксимировать произвольные нелинейные динамические системы. Для синтеза нейросетевого наблюдателя не нужна математическая модель системы, необходимы только обучающие

данные. По сравнению с фильтром Калмана нейросетевой наблюдатель требует меньше вычислительного времени, что снижает стоимость реализации. Кроме того, в случае специальной микропроцессорной структуры (например, программируемой логической интегральной схемы – FPGA) время, необходимое для запуска одного цикла алгоритма РНС, может быть значительно снижено за счет выполнения параллельной обработки данных – в отличие от фильтра Калмана, алгоритм которого последовательный [9]–[11].

Целью данной статьи является синтез нейросетевого наблюдателя, относящийся к рекуррентным нейронным сетям по схеме Элмана, для восстановления неизмеряемых электромеханических параметров состояния в системе управления СЭП наведения ОМК с учетом влияния нелинейных возмущений и помех.

Рекуррентные нейронные сети Элмана, архитектура и обучение. В общем случае искусственные нейронные сети (ИНС) представляют собой компьютерную программу, обладающую способностью к обучению и сохранению полученного знания. Знания, сохраняющиеся в синаптических весах, программа получает в процессе обучения. ИНС включают себя искусственные нейроны, которые имитируют работу мозга человека [12]. Общий вид детализированной архитектуры искусственного нейрона представлен на рис. 1.




Рис. 1

Математическую модель искусственного нейрона (рис. 1) можно записать следующим образом:

$$\begin{cases} s = \sum_{i=1}^n u_i w_i + b; \\ y = F(s), \end{cases}$$

где $u_1, u_2, \dots, u_n$ – входные сигналы нейрона; $w_1, w_2, \dots, w_n$ – синаптические веса нейрона; y – вы-

ходной сигнал нейрона; b – пороговое значение; $F(s)$ – функция активации нейрона.

Функция активации нейрона $F(s)$ выражает выходной сигнал нейрона в зависимости от индуцированного локального поля s . Основные типы функции активации, реализованной в пакете Neural Networks Tool в среде MatLab/Simulink, представлены в табл. 1.

Таблица 1

Тип функции активации	Функция
Линейная (purelin)	$F(s) = ks$, k – коэффициент активации
Линейная с ограничением (satlins)	$F(s) = \begin{cases} 1, & s \geq P, \\ ks, & s < 1, \\ -1, & s \leq -P, \end{cases}$ P – постоянный коэффициент
Ступенчатая с ограничением (пороговая, hardlim)	$F(s) = \begin{cases} 1, & s \geq P, \\ 0, & s < 0 \end{cases}$
Логистическая сигмоидальная (logsig)	$F(s) = \frac{1}{1 + \exp(-ks)}$
Гиперболическая тангенциальная (tansig)	$F(s) = \tanh(s) = \frac{1 - e^{-2s}}{1 + e^{-2s}}$

Главные особенности архитектуры ИНС – количество слоев в скрытом слое и тип нейронов. Эти параметры влияют в основном на скорость и качество обучения, а также на способность регулирования системы управления в динамическом режиме. В литературе ИНС разделяется на три основных класса в зависимости от их архитектуры: 1) однослойные сети с прямой связью (single layer feedforward neural networks); 2) многослойные сети с прямой связью (multi layer feedforward neural networks); 3) рекуррентные нейронные сети, или динамические ИНС с обратной связью (recurrent neural networks).

Система управления СЭП наведения ОМК представляет собой нелинейный упругий объект, поэтому для его синтеза целесообразно применять наблюдатель переменных состояния с рекуррентной нейронной сетью, выполненной по схеме Элмана [13]–[14]. Динамические РНС Элмана – это многослойные персептроны, содержащие в себе задержки по входу и/или выходу, благодаря которым РНС по схеме Элмана может обрабатывать данные сложных нелинейных объектов. Из рис. 2 видно, что архитектура РНС по схеме Элмана относится к классу многослойных нейронных сетей с локальными обратными свя-




Рис. 2




Рис. 3

зями задержек, замкнутыми от скрытых к контекстным нейронам.

В этом случае скрытые нейроны записывают свои предыдущие состояния, что позволяет сохранять выходную информацию скрытых нейронов на один или несколько тактов, после чего переводить их на входной слой. РНС по схеме Элмана оптимально подходит для идентификации в нелинейных системах управления.

Запишем РНС Элмана в форме модели пространства состояний с обратными связями задержек, содержащей m входов, n нейронов первого скрытого слоя, охваченных обратными связями через элементы задержки, и p нейронов выходного слоя. Тогда математическая модель РНС Элмана описывается дискретной нелинейной системой дифференциальных уравнений

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

где $\mathbf{x}(k)$ – n -мерный вектор состояния системы, состоящий из n нейронов первого скрытого слоя РНС; $\mathbf{u}(k)$ – m -мерный вектор входов, состоящий из m входов РНС; $\mathbf{y}(k)$ – p -мерный вектор входов, состоящий из p нейронов выходного слоя; W_a – $(n \times n)$ -мерная матрица синаптического веса нейронов первого скрытого слоя; W_b – $(n \times m)$ -мерная матрица синаптического веса нейронов на входе РНС; C – $(m \times p)$ -мерная матрица синаптического веса нейронов выходного слоя; $f(\cdot)$ – нелинейные активационные функции.

Важное преимущество рекуррентной нейронной сети Элмана, описываемой в виде векторно-матричной модели (1), заключается в ее способ-

ности аппроксимировать различные нелинейные динамические системы.

Рассмотрим задачу обучения РНС Элмана. В настоящее время существуют два метода обучения: «онлайн» (рис. 3, а) и «офлайн» (рис. 3, б).

Процесс «офлайн-обучения» РНС, рассматриваемый в данной статье, предполагает, что переменная состояния объекта получается на выходе РНС Элмана. В этом случае обучающее множество РНС Элмана состоит из управляющих сигналов объекта и измеряемых переменных состояния с задержками, как в моделях NARMA [12], т. е.

$$\mathbf{M}_{o,m} = [\mathbf{u}(k), \mathbf{u}(k-1), \dots, \mathbf{d}(k), \mathbf{d}(k-1), \dots]^T, \quad (2)$$

где $\mathbf{M}_{o,m}$ – обучающее множество РНС Элмана; $\mathbf{u}(k)$ – вектор управляющего сигнала объекта управления в момент времени k ; $\mathbf{d}(k)$ – вектор реальных значений измеряемых переменных состояния.

Процесс обучения РНС Элмана относится к вычислению синаптических матриц W_a и W_b в (1) с обучающим множеством (2), т. е. необходима оптимизация функционала качества РНС $E(w)$, который можно записать в виде среднеквадратической ошибки (СКО) по всем N образам обучающего множества:

$$E(w) = \frac{1}{N} \sum_{i=1}^N [\mathbf{d}_i(k) - \hat{\mathbf{y}}_i(k)]^2 = \frac{1}{N} \sum_{i=1}^N \mathbf{e}_i^2(k), \quad (3)$$

где $\mathbf{e}_i(k) = \mathbf{d}_i(k) - \hat{\mathbf{y}}_i(k)$ – вектор ошибки между значением вектора выходного сигнала РНС Элмана

на $\hat{\mathbf{y}}_i(k)$ и его реальным значением $\mathbf{d}_i(k)$ на k -й итерации; i – индекс обучающего образа.

К наиболее популярным алгоритмам обучения РНС Элмана для оптимизации функционала качества (3) можно отнести: алгоритм обратного распространения градиентного спуска (traingd); алгоритм обратного распространения градиентного спуска с адаптивным управлением (trainidx), алгоритм обратного распространения Левенберга–Марквардта (trainlm); алгоритм обратного распространения градиентного спуска по масштабированию сопряжения (trainscg) [12].

Нейросетевой наблюдатель состояния в электроприводе ОМК. Рассматриваемый электропривод ОМК как объект управления (ОУ) представляет собой нелинейную двухмассовую упругую систему [1]. Структурная схема системы оптимального управления СЭП наведения по горизонтальной оси ОМК с использованием нейросетевого наблюдателя состояния и оптимального регулятора скорости представлена на рис. 4, где J_1 – суммарный момент инерции ротора двигателя, вала оси и внутренних колец подшипников (первая масса); J_2 – момент инерции трубы ОМК (вторая масса); b_{21} – коэффициент демпфирования вала; c_{21} – коэффициент жесткости; ω_1 – угловая скорость первой массы; φ_2 , ω_2 – угловые положение и скорость второй массы соответственно; φ_0 – зазор в кинематике редуктора;




Рис. 4

M_{21} – момент упругой связи между массами; M_{f1} , M_{f2} – нелинейные моменты трения движения в подшипниках первой и второй масс; M_c – внешний возмущающий момент, воздействующий на вторую массу; $\hat{M}_{21}$, $\hat{\omega}_2$ – оценки упругого момента и угловой скорости второй массы на выходе нейросетевого наблюдателя Элмана; β_{Σ} , T_{Σ} – коэффициент передачи и постоянная времени регулятора тока РТ; $\mathbf{K} = [k_1, k_2, k_3, k_4]$ – вектор коэффициентов оптимального регулятора скорости; $\varphi_{\text{зад}}$ – задающий сигнал углового положения на входе регулятора положения РП; M_d – электромагнитный момент двигателя; $k_{p.c}$ – коэффициент передачи регулятора скорости; c_d – конструктивный коэффициент двигателя; i_d – ток двигателя.

Внешним контуром (рис. 4) служит регулятор положения, замыкающийся по угловому положению второй массы (φ_2), который представлен пропорционально-интегральным (ПИ) регулятором, настроенным на оптимум по модулю. Внутренним по отношению к контуру положения служит контур регулирования скорости, замыкающийся по вектору переменных состояния ОУ с помощью нейросетевого наблюдателя Элмана.

Математическое описание ОУ можно записать в виде системы дифференциальных уравнений:

$$\begin{cases} \frac{dM_d}{dt} = -\frac{1}{T_{\Sigma}} M_d - \frac{\beta_{\Sigma}}{T_{\Sigma}} \omega_1 + \frac{\beta_{\Sigma}}{T_{\Sigma}} u_{p.c}; \\ J_1 \frac{d\omega_1}{dt} = M_d - M_{21} - b_{21}(\omega_1 - \omega_2) - M_{f1}; \\ \frac{dM_{21}}{dt} = c_{21}(\omega_1 - \omega_2); \\ J_2 \frac{d\omega_2}{dt} = M_{21} + b_{21}(\omega_1 - \omega_2) - M_{f2} - M_c; \\ \frac{d\varphi_2}{dt} = \omega_2, \end{cases}$$

где $u_{p.c}$ – вектор управляющего воздействия

В рассматриваемом случае нейросетевой наблюдатель Элмана используется для восстановления неизмеряемых переменных состояния в виде упругого момента ($\hat{M}_{21}$) и угловой скорости второй массы ($\hat{\omega}_2$). Архитектура нейросетевого наблюдателя Элмана для оценки переменных со-




Рис. 5

стояния в системе управления СЭП наведения ОМК показана на рис. 5.

Нейросетевой наблюдатель (рис. 5) представляет собой трехслойную РНС Элмана с размерностью 6-15-3, которая состоит из 6 нейронов во входном слое, 15 нейронов в скрытых слоях и двух нейронов в выходном слое. В качестве входных сигналов нейросетевого наблюдателя используются данные тока (i_d) и угловой скорости (ω_1) двигателя с задержкой. Глубина единичных задержек на входе РНС Элмана равна двум. Функции активации в скрытых слоях – гиперболические тангенциальные (tansig), а в выходном слое – линейная с ограничением (satlins).

Результаты моделирования. В данной статье исследуется влияние алгоритмов обучения на качество оценки состояния нейросетевого наблюдателя Элмана в замкнутой системе управления СЭП положения ОМК.

Имитационная модель замкнутой системы СЭП положения ОМК в среде MatLab/Simulink показана на рис. 6. В блоке Subsystem 1 введена математическая модель ОМК в виде двухмассовой упругой системы, электромеханические параметры которой подробно описаны в [15]. Блок Subsystem 2 является оптимальным регулятором скорости, блок Subsystem 3 представляет собой ПИ-регулятор положения.

В имитационной модели (рис. 6) блок нейросетевого наблюдателя Элмана (Elman Neural Network) реализуется с помощью пакета приложения Neural Networks Tool, имитационная модель которого представлена на рис. 7.




Рис. 6




Рис. 7

Данные обучающего тестового множеств для процесса обучения собираются датчиками тока (i_d) и скорости (ω_1) двигателя, количество которых составляет 10^6 образцов. Дискрета для процесса обучения РНС Элмана равна $T_s = 10^{-4}$ с. Значение задающей угловой скорости, поступающей на вход регулятора скорости равно 10^{-2} рад/с. Внешний возмущающий момент сопротивления $M_c = 50$ Н · м воздействует на вторую массу через 2 с после начала переходного процесса.

Для исследования влияния на СКО оценки переменных состояния при обучении нейросетевого наблюдателя Элмана используются различные обучающие алгоритмы в течение одинаковых промежутков времени и неизменные вычислительные параметры компьютера.

На рис. 8–10 показаны результаты моделирования оценки угловой скорости второй массы и упругого момента между массами после процесса обучения нейросетевого наблюдателя Элмана (рис. 8 – результаты оценки обучения с алгоритмом градиентного спуска (traingd); рис. 9 – результаты оценки обучения с алгоритмом градиентного спуска по масштабированию сопряжения (trainscg); рис. 10 – результаты оценки обучения с

алгоритмом Левенберга–Марквардта (trainlm)), где I , I' – упругий (M_{21}) и восстановленный упругий ($\hat{M}_{21}$) моменты между массами соответственно; 2 , $2'$ – угловая (ω_2) и восстановленная угловая ($\hat{\omega}_2$) скорости второй массы соответственно.

Результаты сравнения значений СКО обучения РНС Элмана в качестве нейросетевого наблюдателя состояния между обучающими алгоритмами приведены в табл. 2.




Рис. 8




Рис. 9




Рис. 10

Таблица 2

Тип обучающего алгоритма	СКО обучения	Количество эпох
Алгоритм градиентного спуска (traingd)	26.3	31
Алгоритм градиентного спуска по масштабированию сопряжения (trainscg)	12.1	458
Алгоритм Левенберга–Марквардта (trainlm)	0.25	166

Результаты моделирования, представленные на рис. 8–10 и в табл. 2, показывают, что алгоритм градиентного спуска и алгоритм градиентного спуска по масштабированию сопряжения совершенно не справляются с поставленной задачей из-за большого значения СКО. Алгоритм обучения Левенберга–Марквардта справляется с

поставленной задачей наилучшим образом при малом значении СКО = 0.25.

Предложен метод синтеза нейросетевого наблюдателя на основе рекуррентных нейронных сетей Элмана, позволяющий идентифицировать электромеханические переменные состояния в системе управления СЭП наведения ОМК по данным сигналов обратной связи тока и угловой скорости двигателя. Результаты моделирования показали, что эффективность применения нейросетевого наблюдателя зависит от выбранной архитектуры, обучающего алгоритма рекуррентных нейронных сетей Элмана и связана с точностью их оценки.

СПИСОК ЛИТЕРАТУРЫ

1. Борцов Ю. А., Соколовский Г. Г. Автоматизированный электропривод с упругими связями. СПб.: Энергоатомиздат, 1992.
2. Огородников Ю. И. Синтез наблюдателей состояния для линейных моделей упругих конструкций // Современные технологии. Системный анализ. Моделирование. 2016. № 4. С. 25–36.
3. Phuong T. H., Belov M. P., Van Lan N. State estimation of nonlinear electromechanical system using extended Kalman filter // III IEEE Intern. Conf. on Control in Technical Systems (CTS). SPb, 2019. P. 172–175.
4. Ji J. K., Sul S. K. Kalman filter and LQ based speed controller for torsional vibration suppression in a 2-mass motor drive system // IEEE Transactions on Industrial Electronics. 1995. № 42 (6). P. 564–571.
5. Szabat K., Orłowska-Kowalska T., Dyrzyński K. P. Extended Kalman filters in the control structure of two-mass drive system // Bulletin of the Polish Academy of Sciences: Technical Sciences. Vol. 54, № 3. 2006. P. 315–325.
6. Козлова Л. Е., Боловин Е. В. Исследование статистики и динамики замкнутого бездатчикового асинхронного электропривода собственных нужд ТЭС по схеме ТРН-АД с нейросетевым наблюдателем угловой скорости // Современные проблемы науки и образования. 2014. № 3. С. 1182014.
7. Белов М. П., Фьюнг Ч. Х., Чыонг Н. К. Разработка рекуррентных нейронных сетей в задачах идентификации систем управления следящими электроприводами крупного радиотелескопа // Изв. СПбГЭТУ «ЛЭТИ». 2018. № 8. С. 43–51.
8. Kazmierkowski M. P., Orłowska-Kowalska T. Neural networks state estimation and control in converter-fed induction motor drives // Soft Computing in Industrial Electronics. Springer. 2002. P. 45–94. URL: https://link.springer.com/chapter/10.1007/978-3-7908-1783-6_2 (дата обращения 14.01.21).
9. Omondi A. R., Rajapakse J. C. FPGA implementations of neural networks. New York: Springer. 2006.
10. Moussa M., Areibi S., Nichols K. On the arithmetic precision for implementing back-propagation networks on FPGA: a case study // FPGA Implementations of Neural Networks. Springer. 2006. P. 37–61.
11. Lee C. R., Salic Z. High-performance FPGA-based implementation of Kalman filter // Microprocessors and Microsystems. 1997. Vol. 21 (4). P. 257–265.

12. Хайкин С. Нейронные сети: полный курс / пер. с англ. М.: Вильямс, 2006.

13. Elman J. L. Finding structure in time // Cognitive Science. 1990. Vol. 14. P. 179–211.

14. Flow estimation using an Elman networks / L. B. Neto, P. G. Coelho J. C. C. B. Soares de Mello, L. Angulo-Meza // 2004 IEEE Intern. Joint Conf. on Neural Net-

works. Conf.: Budapest, Hungary, 2004. Vol. 2. P. 831–836.

15. Белов М. П., Лань Н. В. Разработка дискретного оптимального квадратичного управления электроприводом наведения оптико-механических комплексов // Изв. СПбГЭТУ «ЛЭТИ». 2020. № 5. С. 78–84.

M. P. Belov, N. Van Lanh
Saint Petersburg Electrotechnical University

STATE ESTIMATION BASED NEURAL NETWORK OBSERVER IN ELECTRIC DRIVE CONTROL SYSTEM OF OPTICAL-MECHANICAL COMPLEXES

Proposes an application of neural state observer using recurrent neural networks to estimate electromechanical variable coordinates in the tracking electric drive of the optical-mechanical complex control system. The mathematical description of the electric drive of optical-mechanical complex in the form of a two-mass electromechanical system with elastic connections is developed. These elastic vibrations of the two-mass system are damped by using feedback signals from the estimated elastic moment and load velocity from neural network observer. The architectures of dynamic recurrent neural networks according to the Elman scheme are analyzed in the form of state space model, which allows it to approximate a wide class of nonlinear dynamic systems. During computer simulation in the MATLAB/Simulink software environment, the comparison of the root-mean-square error between different learning algorithms for Elman's recurrent neural networks was carried out to study their accuracy estimates coordinates in a closed loop control system of optical-mechanical complex.

Optical-mechanical complex, recurrent neural networks Elman, neural state observer, two-mass elastic system

УДК 621.314.263

А. Г. Воронцов
ООО «НПЦ СЭС» СПбГЭТУ «ЛЭТИ»

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

В. В. Глушаков, Н. И. Фёдоров
АО «Силовые машины»

Моделирование ЭЭС с продольным СТАТКОМ методами взаимосвязанных подсистем для анализа режимов синхронизации напряжений двух ЛЭП

Питание потребителей электроэнергии 1-й категории осуществляется от двух взаимно независимых источников. В ряде случаев перерыв питания недопустим и необходимы согласование напряжений и кратковременная или длительная параллельная работа двух источников. Для анализа возможностей статических продольных компенсаторов по согласованию напряжений двух ЛЭП построена компьютерная модель. Моделирование выполнено посредством методологии расчета систем по взаимосвязанным подсистемам, обеспечивающей минимальные затраты машинного времени. Статический продольный компенсатор позволяет согласовать либо фазы, либо действующие значения напряжений ЛЭП. При согласовании фаз напряжений действующие значения согласовываются другим устройством, например трансформатором с отпайками. При согласовании действующих напряжений двух ЛЭП согласование фаз напряжений должно осуществляться также другим устройством, например фазоповоротным трансформатором.

Продольный СТАТКОМ, электроэнергетическая система, высоковольтные линии электропередач, моделирование, синхронизация напряжений, статические продольные компенсаторы

Мегаполисы, заводы, рудники и многие другие объекты по надежности электроснабжения

относятся к потребителям 1-й категории [1]. Их электроснабжение в электроэнергетических си-