

УДК 621.331

doi:10.20998/2413-4295.2023.02.05

ОПТИМІЗАЦІЯ ВИБОРУ СТУПНЯ СКЛАДНОСТІ МОДЕЛІ ДВИГУНА ПОСТІЙНОГО СТРУМУ ДЛЯ СИСТЕМИ З ВИКОРИСТАННЯМ НЕЙРОННОЇ МЕРЕЖІ

Б. В. ВОРОБІЙОВ¹, С. О. СЕНЧЕНКО^{1*}, В. К. РИБАКОВ², Я. В. ЛІХНО¹, Л. ХАНЬ¹

¹ Автоматизовані електромеханічні системи, НТУ "ХПІ", м. Харків, УКРАЇНА

² ВЛ ТОВ "ЦВВО", заступник керівника лабораторії, м. Харків, УКРАЇНА

*e-mail: Serhii.Senchenko@khpі.edu.ua

АНОТАЦІЯ Побудовано математичну та комп'ютерну модель системи керування моментом двигуна постійного струму з незалежним збудженням за допомогою нейроконтролера NARMA 2. NARMA – нелінійна авторегресійна модель ковзного середнього є однією з базових структур дискретної та нелінійної моделі. Завдання полягало в проведенні порівняльного аналізу роботи системи керування на основі нейроконтролера з використанням моделі об'єкта різного ступеня складності. Для експерименту було побудовано три моделі об'єкта з різним ступенем деталізації, а отже і надійності об'єкта. Повна модель включає модель двигуна постійного струму з незалежним збудженням, яка враховує всі основні параметри машини постійного струму, параметри внутрішнього тертя, кола збудження і т. д. Спрощена модель є лінійною апроксимацією двигуна постійного струму системою другого порядку, яка враховує як механічні, так і електричні постійні часу. Найпростіша модель є лінійною апроксимацією двигуна постійного струму аперіодичною ланкою першого порядку, яка враховує лише механічну постійну часу. Нейроконтролер був навчений за допомогою наведених вище моделей об'єктів та проведено експеримент, щоб опрацювати еталонний сигнал крутного моменту системою. Для кожного з трьох випадків навчання нейроконтролера було встановлено на 1000 epoch, так як подальше підвищення продуктивності навчання є непотрібним через величезні втрати часу на обчислення. Було використано нейроконтролер NARMA-L2, який ще називають управлінням лінеаризації зворотного зв'язку. Цей контролер може бути реалізований за допомогою попередньо ідентифікованої моделі об'єкта NARMA-L2. Нейронні мережі, які навчені на спрощених моделях об'єктів не враховують більшість електричних процесів у двигуні постійного струму, особливо обмотка збудження взагалі не моделюється. Отримані результати порівнювали з використанням нейроконтролера як регулятора крутного моменту. Подальші дослідження в цьому напрямку передбачають дослідження необхідної обчислювальної потужності для мікропроцесорної реалізації нейроконтролера.

Ключові слова: нейроконтролер; регулювання; система керування; модель об'єкта; моделювання процесів; приводи.

OPTIMIZATION OF THE DC MOTOR MODEL COMPLEXITY LEVEL SELECTION FOR THE SYSTEM USING A NEURAL NETWORK

B. VOROBIOV¹, S. SENCHENKO¹, V. RYBAKOV², Y. LIKHNO¹, L. KHAN¹

¹ Automated electromechanical systems, NTU "KhPI", Kharkiv, UKRAINE

² "CC Ex-EQUIPMENT" Ltd., Kharkiv, UKRAINE

ABSTRACT A mathematical and computer model of the torque control system of a DC motor with independent excitation was built using the NARMA 2 neurocontroller. NARMA - a nonlinear moving average autoregressive model is one of the basic structures of a discrete and nonlinear model. The task was to conduct a comparative analysis of the operation of the neurocontroller-based control system using plant model of varying complexity. For the experiment, three models of the object were built with different degrees of detail, and therefore the reliability of the object. The full model includes an independently excited DC motor model that takes into account all the main parameters of the DC machine, internal friction parameters, excitation circuits, etc. The simplified model is a linear approximation of the DC motor by a second-order system that takes into account both mechanical and electrical time constants. The simplest model is a linear approximation of a DC motor by a first-order aperiodic link that takes into account only the mechanical time constant. The neurocontroller was trained using the above object models and an experiment was conducted to process the reference torque signal by the system. For each of the three training cases, the neurocontroller was set to 1000 epochs, since further training performance improvement is unnecessary due to the huge loss of computation time. The NARMA-L2 neurocontroller, which is also called feedback linearization control, was used. This controller can be implemented using a pre-identified NARMA-L2 object model. Neural networks that are trained on simplified object models do not take into account most of the electrical processes in a DC motor, especially the excitation winding is not modeled at all. The obtained results were compared with the use of a neurocontroller as a torque regulator. Further research in this direction involves the study of the necessary computing power for the microprocessor implementation of the neurocontroller.

Keywords: neurocontroller; regulation; control system; plant model; process modelling; drives.

Вступ

Різноманітність сучасних систем електроприводів, способів їх застосування, величезна кількість складних технологічних пристроїв,

керування якими вимагає все більшої надійності, точності та інваріантності [1-5] пред'являє підвищені вимоги до систем керування. У свою чергу, це призводить до широкого використання контролерів, побудованих на основі нейронних мереж. Такий

підхід забезпечує гнучкість використання однієї і тієї ж базової системи керування для величезної різноманітності об'єктів керування і з широкою зміною їх параметрів [6-12].

В даний час нейронні мережі знайшли дуже широке застосування в системах прогнозування, захисту і при роботі з великими масивами даних. Також нейроконтролери часто використовуються для вирішення завдань управління. Коло цих завдань і об'єкт керування може бути практично будь-яким - двигуни постійного [11,12] або змінного [7,8] струму, маятники [9], системи електромеханічної стабілізації (наприклад, у камерах) тощо.

Найскладнішим завданням синтезу нейроконтролерів є навчання нейронної мережі. Це найдовший і трудомісткий процес, від результату якого залежить, як нейроконтролер впорається із завданням. Для навчання нейронних мереж вирішенню задач керування використовуються два основних методи - масив попередньо зібраних даних (наприклад, емпіричних) або побудова об'єктної (еталонної) моделі. Для лінійних або квазілінійних систем найчастіше використовується метод з моделлю об'єкта, оскільки такі системи можна більш-менш точно описати математично, що дозволить нейроконтролеру передбачити поведінку системи у разі змінного налаштування збурюючих впливів, а також при зміні параметрів системи в достатньо широких межах [9,10].

Масове впровадження нейронних мереж значно підвищує вимоги до продуктивності мікроконтролерів/комп'ютерів/ПЛІС, на яких побудовані системи керування. Це, в свою чергу, призводить до подорожчання системи або (при використанні одних і тих же мікроконтролерів) до уповільнення роботи системи керування, збільшення часу дискретизації системи, погіршення якості регулювання тощо.

Питання, пов'язані з динамічною корекцією моделі об'єкта, а також ітераційним навчанням нейронної мережі при зміні режиму роботи об'єкта керування, детально розглянуті в [13].

Продуктивність контролера NARMA L2 порівнюється для різних моделей установок у [14], однак отримані результати не можна узагальнити та ідентифікувати для конкретної системи з використанням різних алгоритмів. Під час навчання нейронної мережі використовуються різні моделі об'єкта, однак це пов'язано з різним підходом до керування та стосується саме продуктивності системи.

У всіх досліджуваних джерелах приділяється увага використанню нейроконтролерів, робастності систем, продуктивності об'єкта керування при використанні нейроконтролера замість інших контролерів, а також багатьом іншим аспектам їх використання, але увагу впливу різної точності моделей об'єктів під час навчання нейронної мережі на якість керування об'єктом ніде не враховувалося.

Мета роботи

Метою роботи є дослідження навчання нейронних мереж на моделях об'єктів різної складності, що дасть змогу виявити прийнятне спрощення, а також дослідити залежність якості перехідних процесів від складності моделі об'єктів при навчанні нейронних мереж відповідно до зменшення необхідної обчислювальної потужності для реалізації нейроконтролера.

Базова математична модель

Для вирішення поставленої задачі в рамках дослідження побудовано математичну модель системи керування струмом двигуна постійного струму. В основній комп'ютерній моделі використовується блок машини постійного струму з пакету SimPowerSystems [15]. Загальний вигляд комп'ютерної моделі наведено на рис. 1.

Нижче наведено параметри моделювання, використані в моделі. Використовувана модель двигуна постійного струму серії П11 з 1500 об/хв та потужністю 0,3 кВт.

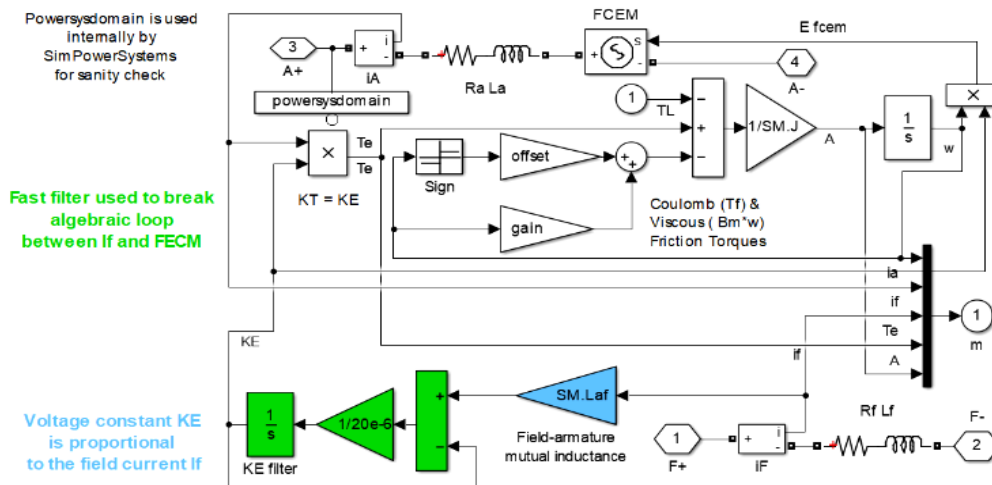


Рис. 1 – Комп'ютерна модель двигуна постійного струму в Matlab, Simulink

Номинальна напруга $U_n = 220$ В. Опір якоря $R_a = 6,75$ Ом, індуктивність якоря $L_a = 0,085$ Гн. Опір поля $R_f = 670$ Ом і індуктивність поля $L_f = 5,63$ Гн. Взаємна індуктивність поля якоря $L_{af} = 0,95$ Гн. Крутний момент на константу струму машини постійного струму з постійним магнітом, Нм/А. Повна інерція машини постійного струму $J = 0,0105$ кг·м².

Ця модель враховує як електричні, так і механічні процеси в двигуні постійного струму.

Моделі об'єктів та навчання нейроконтролера

У цьому дослідженні використовується нейроконтролер NARMA-L2, який також називають управлінням лінеаризації зворотного зв'язку. Принцип роботи нейроконтролера NARMA-L2 полягає в лінійній апроксимації моделі об'єкта, яка використовується для навчання нейронної мережі. Центральна ідея цього типу керування полягає в перетворенні динаміки нелінійної системи в лінійну динаміку шляхом усунення нелінійностей. У цьому розділі представлено зв'язки, які використовуються в нейроконтролері для побудови внутрішньої лінеаризованої моделі, і те, як ця ідентифікована модель використовується для синтезу нейрорегулятора. Наступна математична модель лежить в основі блоку керування NARMA-L2 у MATLAB, наборі блоків Neural Network Toolbox™.

Процес ідентифікації моделі прогностичного управління включає декілька етапів. По-перше, це лінеаризація зворотного зв'язку основної системи, щоб отримати дані про те, як система працює (NARMA L2), щоб отримати можливість керувати нею. Навчання нейронної мережі дає прогноз динаміки системи. На цьому етапі необхідно вибрати структуру моделі. NARMA - нелінійна авторегресійна модель ковзного середнього є однією з базових структур дискретної та нелінійної моделі [16]:

$$y(k+d) = N[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-n+1)], \quad (1)$$

де $u(k)$ – вхідний сигнал, а $y(k)$ – вихідний сигнал. На етапі ідентифікації моделі необхідна апроксимація нелінійної функції (N) при навчанні нейронної мережі. На основі такої ідентифікації будуються нейромережеві прогностичні контролери.

Базова траєкторія $y(k+d) = y_r(k+d)$, за якою повинен керувати вихідний сигнал, потребує етапу розробки форми нелінійного регулятора [17]:

$$u(k) = G[y(k), y(k-1), \dots, y(k-n+1), y_r(k+d), u(k-1), \dots, u(k-m+1)]. \quad (2)$$

Однак існує значна складність використання такого типу контролера: використання динамічного зворотного поширення потрібне для мінімізації середньоквадратичної помилки та створення G-функції в процесі навчання [16,17]. Нарендра та

Мухопадхьяй запропонували рішення [18], яке бере деяку еталонну наближену модель системи як основу прогнозування для збільшення швидкості обчислень. Цей метод ліг в основу створення наближеної моделі NARMA-L2 [19]:

$$\hat{y}(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] \cdot u(k). \quad (3)$$

Ця модель є супутньою формою, де наступний вхід контролера $u(k)$ не міститься всередині нелінійності. Перевага цієї форми полягає в тому, що ви можете розв'язати контрольний вхід, який змушує системний вихід слідувати посилянню $y(k+d) = y_r(k+d)$. Отриманий контролер мав би вигляд [19]:

$$u(k) = (y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)]) / (g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)]). \quad (4)$$

Пряме використання цього рівняння може спричинити проблеми з реалізацією, оскільки ви повинні визначити вхід керування $u(k)$ на основі одночасного виходу $y(k)$. Отже, замість цього використовуйте модель [19]:

$$y(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-n+1)] + g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)] \cdot u(k+1), \quad (5)$$

де $d \geq 2$.

На рис. 2 наведено структуру представлення нейронної мережі [20].

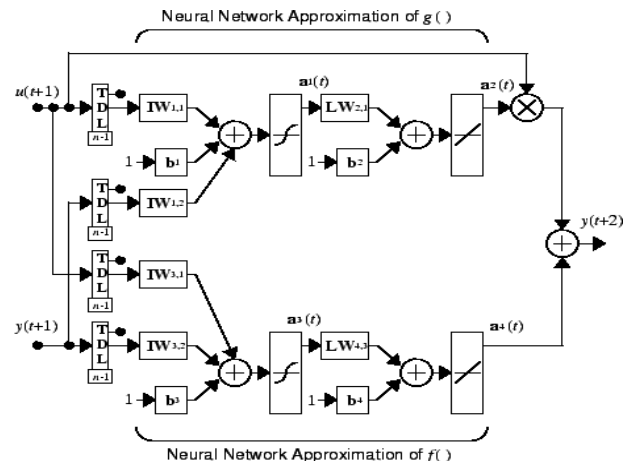


Рис. 2 – Структура нейронної мережі

Використовуючи модель NARMA-L2, ви можете отримати контролер [19]:

$$u(k+1) = (y_r(k+d) - f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]) / (g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]), \quad (6)$$

що реалізується при $d \geq 2$.

На рис. 3 показана блок-схема контролера NARMA-L2 [20].

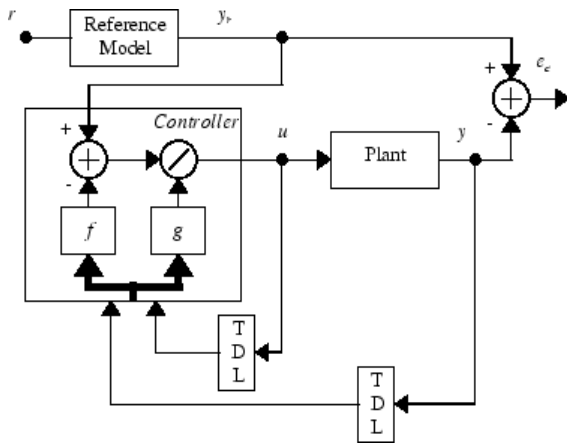


Рис. 3 – Блок-схема контролера NARMA-L2

Цей контролер може бути реалізований за допомогою попередньо ідентифікованої моделі об'єкта NARMA-L2 [20], як показано на рис. 4.

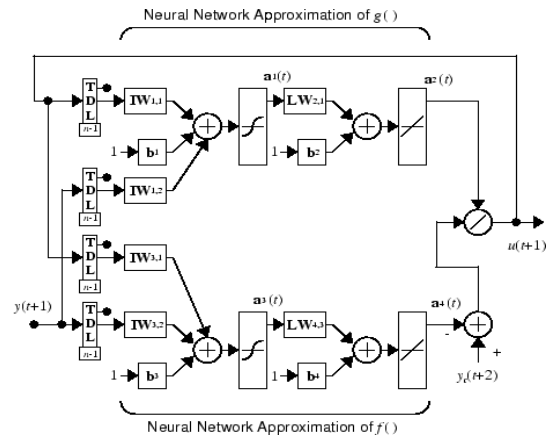


Рис. 4 – Раніше ідентифікована модель об'єкта NARMA-L2

Використовуючи блок управління NARMA-L2, який міститься в Neural Network Toolbox™, була побудована наступна узагальнена модель (рис. 5).

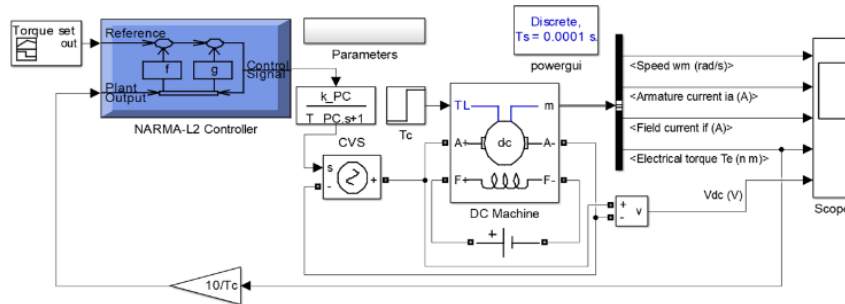


Рис. 5 – Узагальнена модель з нейроконтролером

На рис. 6 представлені основні налаштування, які використовуються для ідентифікації моделей об'єктів у нейроконтролері NARMA L2. Ці параметри відповідають налаштуванням напруги системи управління основною моделлю.

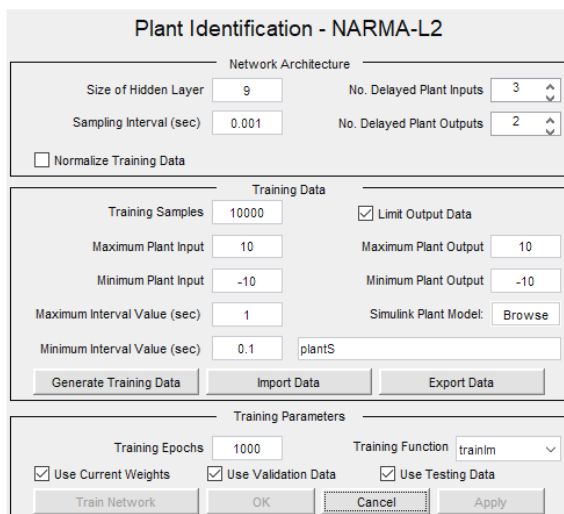


Рис. 6 – Параметри навчання нейронної мережі ідентифікації моделі об'єкта

Для експерименту було побудовано три моделі об'єкту з різним ступенем деталізації. Модель об'єкту є еталонною моделлю, яка використовується для навчання нейронної мережі контролера [21]. У разі використання NARMA-L2, нейронна система навчається шляхом попередньої лінеаризації моделі об'єкта.

Перша модель - S (найпростіша) є лінійною апроксимацією двигуна постійного струму аперіодичною ланкою першого порядку, яка враховує лише механічну постійну часу. Блок-схема моделі S показана на рис. 7.




Рис. 7 – Блок-схема моделі об'єкта S

Друга модель, M (середнє), є лінійною апроксимацією двигуна постійного струму системою другого порядку, яка враховує як механічні, так і електричні постійні часу. Блок-схема моделі M показана на рис. 8.




Рис. 8 – Блок-схема моделі об'єкта M

Третя модель - L (велика) включає модель двигуна постійного струму з пакету SimPowerSystems, яка враховує всі основні параметри машини постійного струму, параметри кола збудження, внутрішнього тертя і т.д. Блок-схема моделі L показано на рис. 9.

На рис. 10 показано продуктивність, час навчання та кількість необхідних епох для досягнення необхідного результату навчання. Для кожного з трьох випадків навчання нейроконтролера було встановлено на 1000 епох. Для моделі об'єкта S було потрібно 23 ітерації, щоб досягти мінімальної можливої похибки. Для обох моделей об'єктів M і L було проведено всі 1000 ітерацій. Основні параметри контролера були визначені відповідно до моделей S, M і L.

Еталонний сигнал обробки помилок даних верифікаційного сигналу для кожної з трьох моделей об'єктів показано на рис. 11. Результати навчання

показали, що найменша помилка отримана з L моделлю об'єкта.




Рис. 9 – Блок-схема моделі об'єкта L

Найкраща продуктивність системи з моделлю об'єкта S була досягнута в епоху 17. Після цього було проведено 6 ітерацій перевірки. Для обох моделей об'єктів M і L процес навчання було зупинено на епосі 1000. Мінімальна помилка не була досягнута, але подальше підвищення продуктивності навчання є непотрібним через величезні витрати часу на обчислення. На рис. 12 показано результати регресії під час навчання на різних етапах для моделей S, M та L. Для моделі об'єкта S перевірена регресія відповідає приблизно 0,1% розбіжності вихідного сигналу з еталонним ($R = 0,998$). Обидві моделі M і L мають підтверджену регресію $R = 1$.

Progress		S plant model	M plant model	L plant model
Epoch:	0	23 iterations	1000 iterations	1000 iterations
Time:		0:00:01	0:01:03	0:01:11
Performance:	0.0160	6.89e-07	0.00776	0.139
Gradient:	0.119	0.000118	0.0316	1.13
Mu:	0.00100	1.00e-07	0.00100	0.00100
Validation Checks:	0	6	0	0

Рис. 10 – Результат тренувань нейронної мережі




Рис. 11 – Порівняння помилок на виході нейроконтролера перевірки




Рис. 12 – Навчальна регресія (тільки етап перевірки) на різних етапах

На рис. 13 і 14 показано результати навчання нейронної мережі в термінах середньої квадратичної помилки (MSE). Як видно з графіка, зниження MSE відповідає помилці перевірки.




Рис. 13 – Ефективність перевірки за середньоквадратичною помилкою S моделі об'єкта





Рис. 14 – Ефективність перевірки за середньоквадратичною помилкою M і L моделей об'єкта

Час, витрачений на збір даних і навчання нейронної мережі (у відносних одиницях): $t_{train_s} = 1$; $t_{номія_M} = 1,4$; $t_{train_L} = 3,9$.

Середньоквадратична помилка (відхилення вихідного сигналу моделі об'єкта від еталонного сигналу системи) під час навчання відповідно становить: $MSE_S = 8,084e^{-6}$, $MSE_M = 4,33e^{-10}$, $MSE_L = 2,88e^{-10}$.

Моделювання та порівняння

Після навчання нейронної мережі було проведено комп'ютерне моделювання обробки еталонного сигналу крутного моменту.

На рис. 15 показано конструктор сигналу з еталонним сигналом крутного моменту, нормалізованим на 10 В до номінального.

Максимальне відхилення крутного моменту від еталонного сигналу складо: $\Delta T_S = 15\%$, $\Delta T_M = 8\%$, $\Delta T_L = 0,1\%$.




Рис. 15 – Діаграма еталонного сигналу крутного моменту

Головною відмінністю отриманих результатів є той факт, що нейронні мережі, навчені на спрощених моделях об'єктів (S і M), не враховують більшість електричних процесів у двигуні постійного струму, особливо обмотка збудження взагалі не моделюється.

Діаграми крутного моменту двигуна, отримані за допомогою контролера NARMA-L2, навченого на моделях об'єктів S, M, L, показані на рис. 16-18. Для зручності порівняння еталонний сигнал був розрахований на крутний момент ($10 = T_n$).

Результати моделювання обробки еталонного сигналу крутного моменту для тренувальних даних нейронної мережі моделі об'єкта S показують, що, загалом, форма крутного моменту відповідає сигналу налаштування, однак є значні коливання, які призводять до значного перевищення крутного моменту від еталонного. в деяких областях.

Для об'єкта M ситуація приблизно така ж – спостерігаються коливання крутного моменту, однак частота коливань і їх амплітуда менші в порівнянні з моделлю об'єкта S.

Для даних моделі об'єкта L ми отримуємо найкращу продуктивність. У крутному моменті немає низькочастотних коливань і він повністю повторює форму еталонного сигналу. Є невелике перерегулювання,

а також височастотні коливання, які викликані керуючим сигналом, який генерує нейроконтролер.




Рис. 16 – Діаграма крутного моменту (модель об'єкта S)




Рис. 17 – Діаграма крутного моменту (модель об'єкта M)




Рис. 18 – Діаграма крутного моменту (модель об'єкта L)

На рис. 19 показано середні значення крутних моментів усіх трьох випадків, а також позначено максимальне перевищення.




Рис. 19 – Перевищення крутного моменту для випадків S, M і L

З діаграми видно, що криві крутного моменту, отримані шляхом керування нейронною мережею з даними S та M моделей об'єктів, досить близькі з точки зору їх невідповідності сигналу крутного моменту L моделі об'єкту. У більшості випадків такої точності може бути достатньо, особливо якщо система має обмеження продуктивності мікроконтролера, на основі якого буде програмуватися нейронна мережа. Однак у тих випадках, коли крутний момент повинен чітко відпрацьовувати сигнал установки, наприклад, в точних виробництвах, використання спрощених моделей для навчання нейронної мережі неприпустимо.

Висновки

В результаті роботи побудовано математичну та комп'ютерну модель системи керування моментом двигуна постійного струму з незалежним збудженням за допомогою нейроконтролера на базі NARMA L2. Для навчання нейронної мережі було побудовано 3 моделі об'єкта різного ступеня складності, а отже і надійності об'єкта. Використовуючи ці моделі, було навчено нейронну мережу та проведено експеримент, щоб опрацювати еталонний сигнал крутного моменту системою. Також був проведений аналіз самого тренувального процесу. У результаті навчання системи відзначено, що перші дві системи були повністю лінеаризовані (без кусково-лінійної апроксимації).

Виходячи з отриманих результатів, можна відзначити наступне:

- використання лінеаризованої моделі двигуна постійного струму для навчання нейронної мережі виправдано у випадку, коли немає потреби у високій точності, але необхідні відомі переваги використання нейроконтролерів, такі як робастність;
- використання лінеаризованої моделі двигуна постійного струму для навчання дозволяє скоротити час, необхідний для синтезу даних для навчання нейронної мережі, зменшити саму модель об'єкта та внутрішні параметри, які беруть участь у розрахунку вихідного сигналу контролера. Це, в свою чергу, може істотно знизити обчислювальну потужність, необхідну для реалізації цього контролера в реальних системах. Це, у свою чергу, дає можливість отримати майже всі переваги регулювання за допомогою нейроконтролера на більш простому та дешевому обладнанні;
- якщо головним критерієм є точність системи, то необхідно використовувати повну модель об'єкту, яка також враховує електричні процеси в двигуні та обмотці збудження.

Подальші дослідження в цьому напрямку передбачають дослідження необхідної обчислювальної потужності для мікропроцесорної реалізації нейроконтролера з різним ступенем деталізації моделі об'єкта в рамках розв'язання стандартної задачі керування.

Список літератури

1. Vorobiov B., Pshenichnykov D. Modeling of the operation of an asynchronous electric drive of an electric vehicle in slip modes. 25th IEEE international conference on problems

- of automated electric drive. Theory and practice.* 2020. № 1 (25). P. 49–55. doi: 10.1109/PAEP49887.2020.9240797.
2. Vorobiov B., Senchenko S., Pshenichnykov D., Brynza N. and Tymoshchenko A. Neural Network Controller Based Slippage Prevention System For Electric Vehicle. *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWEEK)*. 2022. P. 1–6. doi: 10.1109/KhPIWeek57572.2022.9916436.
 3. Zaitsev R. V., Kirichenko M. V., Minakova K. A., Khrypunov G. S., Drozdov A. N., Khrypunova I. V., Prokopenko D. S. DC–DC Converter for High-Voltage Power Take-Off System of Solar Station. *2nd Ukraine Conference on Electrical and Computer Engineering*. 2019. P. 582-587. doi:10.1109/UKRCON.2019.8879860.
 4. Kirichenko M. V., Khrypunov G. S., Khrypunov M. G., Zaitsev R. V., Drozdov A. N. EMI protection elements on cadmium telluride thin films. *IOP Conference Series: Materials Science and Engineering*. 2018. Vol. 459. P. 012009. doi: 10.1088/1757-899X/459/1/012009.
 5. Liu Z., Peng K., Han L. et al. Modeling and control of rodotic manipulators based on artificial neural networks: a review. *Iran J Sci Technol Trans Mech Eng*. 2023. doi: 10.1007/s40997-023-00596-3.
 6. Uçak K. and Öke Günel G. A novel adaptive NARMA-L2 controller based on online support vector regression for nonlinear systems. *Neural Process. Lett.* 2016. Vol.44, No.3. P. 857–886. doi: 10.1007/s11063-016-9500-7.
 7. George M. and Prasad Basu K. NARMA-L2 controlled variable frequency three-phase induction motor drive. *Eur. J. Sci. Res.* 2012. Vol.70, No.1. P. 98–111.
 8. Wai Rong-Jong, and Alex S. Prasetia. Adaptive neural network control and optimal path planning of UAV surveillance system with energy consumption prediction. *IEEE Access* 7. 2019. P. 126137-126153. doi: 10.1109/ACCESS.2019.2938273.
 9. Liu Yan-Jun, et al. Adaptive neural network control for active suspension systems with time-varying vertical displacement and speed constraints. *IEEE Transactions on Industrial Electronics*. 2019. doi:10.1109/TIE.2019.2893847.
 10. Al-Dunainawi Y., Abbod M. F., and Jizany A. A new MIMO ANFIS-PSO based NARMA-L2 controller for nonlinear dynamic systems. *Engineering Applications of Artificial Intelligence*. 2017. P. 265-275. doi: 10.1016/j.engappai.2017.04.016.
 11. Kassem A. M. MPPT control design and performance improvements of a PV generator powered DC motor-pump system based on artificial neural networks. *Int. J. Electr. Power Energy Syst.* 2012. Vol. 43, No.1. P. 90–98. doi:10.1016/j.ijepes.2012.04.047.
 12. Ullah B. et al. Speed control of separately excited DC motor using NARMA-L2 controller. *2022 international conference on technology and policy in energy and electric power (ICT-PEP), Jakarta, Indonesia*. 2022. P. 43-47. doi: 10.1109/ICT-PEP57242.2022.9988795.
 13. Lu Feng, et al. Iterative learning NARMA-L2 control for turbofan engine with dynamic uncertainty in flight envelope. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*. 2022. Vol. 236, No.7. P. 1282-1294. doi: 10.1177/09544100211029814.
 14. Jeyachandran C., and Rajaram M. Comparative performance analysis of various training algorithms for control of CSTR process using narma-L2 control. *3rd International Conference on Trendz in Information Sciences & Computing (TISC2011)*. *IEEE*. 2011. P. 5-10. doi:10.1109/TISC.2011.6169075.
 15. Alhanjouri M. Speed control of DC motor using artificial neural network. *International Journal of Science and Research*. 2017. Vol. 6, No. 2. P. 2140-2148. doi: 10.21275/ART20172035.
 16. Kravets P., Shymkovych V. Hardware implementation neural network controller on FPGA for stability ball on the platform. *International Conference on Computer Science, Engineering and Education Applications*. Springer, Cham. 2019. P. 247-256. doi: 10.1007/978-3-030-16621-2_23.
 17. Hejia Gao, et al. Neural network control of a two-link flexible robotic manipulator using assumed mode method. *IEEE Transactions on Industrial Informatics*. 2018. P. 755-765. doi:10.1109/TII.2018.2818120.
 18. Bai Weiwei, et al. Adaptive reinforcement learning neural network control for uncertain nonlinear system with input saturation. *IEEE transactions on cybernetics*. 2019. P. 3433-3443. doi:10.1109/TCYB.2019.2921057.
 19. Bhatia V., Kalaichelvi V., Karthikeyan R. Comparison of GA tuned fuzzy logic and NARMA-L2 controllers for motion control in 5-DOF robot. *Int. J. Comput. Appl.* 2017. Vol. 39, No. 2. P. 69–78. doi: 10.1080/1206212X.2017.1281038.
 20. Fodor D., Six J. P., and Diana D. Neural networks applied for induction motor speed sensorless estimation. in *Proc. ISIE'95*. 1995. P. 181-186. doi: 10.1109/ISIE.1995.496623.
 21. George M. and Prasad Basu K. NARMA-L2 controlled variable frequency three-phase induction motor drive. *Eur. J. Sci. Res.* 2012. Vol.70, No.1. P. 98–111.

References (transliterated)

1. Vorobiov B., Pshenichnykov D. Modeling of the operation of an asynchronous electric drive of an electric vehicle in slip modes. *25th IEEE international conference on problems of automated electric drive. Theory and practice*, 2020, 1 (25), pp. 49–55, doi: 10.1109/PAEP49887.2020.9240797.
2. Vorobiov B., Senchenko S., Pshenichnykov D., Brynza N. and Tymoshchenko A. Neural Network Controller Based Slippage Prevention System For Electric Vehicle. *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWEEK)*, 2022, pp. 1–6, doi: 10.1109/KhPIWeek57572.2022.9916436.
3. Zaitsev R. V., Kirichenko M. V., Minakova K. A., Khrypunov G. S., Drozdov A. N., Khrypunova I. V., Prokopenko D. S. DC–DC Converter for High-Voltage Power Take-Off System of Solar Station. *2nd Ukraine Conference on Electrical and Computer Engineering*, 2019, pp. 582-587, doi:10.1109/UKRCON.2019.8879860.
4. Kirichenko M. V., Khrypunov G. S., Khrypunov M. G., Zaitsev R. V., Drozdov A. N. EMI protection elements on cadmium telluride thin films. *IOP Conference Series: Materials Science and Engineering*, 2018, vol. 459, pp. 012009, doi: 10.1088/1757-899X/459/1/012009.
5. Liu Z., Peng K., Han L. et al. Modeling and control of rodotic manipulators based on artificial neural networks: a review. *Iran J Sci Technol Trans Mech Eng.*, 2023, doi: 10.1007/s40997-023-00596-3.
6. Uçak K. and Öke Günel G. A novel adaptive NARMA-L2 controller based on online support vector regression for nonlinear systems. *Neural Process. Lett.*, 2016, vol. 44, 3, pp. 857–886, doi: 10.1007/s11063-016-9500-7.
7. George M. and Prasad Basu K. NARMA-L2 controlled variable frequency three-phase induction motor drive. *Eur. J. Sci. Res.*, 2012, vol.70, 1, pp. 98–111.
8. Wai Rong-Jong, and Alex S. Prasetia. Adaptive neural network control and optimal path planning of UAV surveillance system with energy consumption prediction. *IEEE Access* 7, 2019, pp. 126137-126153, doi: 10.1109/ACCESS.2019.2938273.
9. Liu Yan-Jun, et al. Adaptive neural network control for active suspension systems with time-varying vertical displacement

- and speed constraints. *IEEE Transactions on Industrial Electronics*, 2019, doi: 10.1109/TIE.2019.2893847.
10. Al-Dunainawi Y., Abbod M. F., and Jizany A. A new MIMO ANFIS-PSO based NARMA-L2 controller for nonlinear dynamic systems. *Engineering Applications of Artificial Intelligence*, 2017, pp. 265-275, doi: 10.1016/j.engappai.2017.04.016.
 11. Kassem A. M. MPPT control design and performance improvements of a PV generator powered DC motor-pump system based on artificial neural networks. *Int. J. Electr. Power Energy Syst.*, 2012, vol. 43, No.1, pp. 90–98, doi:10.1016/j.ijepes.2012.04.047.
 12. Ullah B. et al. Speed control of separately excited DC motor using NARMA-L2 controller. *2022 international conference on technology and policy in energy and electric power (ICT-PEP), Jakarta, Indonesia, 2022*, pp. 43-47, doi: 10.1109/ICT-PEP57242.2022.9988795.
 13. Lu Feng, et al. Iterative learning NARMA-L2 control for turbofan engine with dynamic uncertainty in flight envelope. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2022, vol. 236, 7, pp. 1282-1294, doi: 10.1177/09544100211029814.
 14. Jeyachandran C., and Rajaram M. Comparative performance analysis of various training algorithms for control of CSTR process using narma-L2 control. *3rd International Conference on Trendz in Information Sciences & Computing (TISC2011). IEEE*, 2011, pp. 5-10, doi:10.1109/TISC.2011.6169075.
 15. Alhanjouri M. Speed control of DC motor using artificial neural network. *International Journal of Science and Research*, 2017, vol. 6, 2, pp. 2140-2148, doi: 10.21275/ART20172035.
 16. Kravets P., Shymkovych V. Hardware implementation neural network controller on FPGA for stability ball on the platform. *International Conference on Computer Science, Engineering and Education Applications. Springer, Cham.*, 2019, pp. 247-256, doi: 10.1007/978-3-030-16621-2_23.
 17. Hejia Gao, et al. Neural network control of a two-link flexible robotic manipulator using assumed mode method. *IEEE Transactions on Industrial Informatic*, 2018, pp. 755-765, doi:10.1109/TII.2018.2818120.
 18. Bai Weiwei, et al. Adaptive reinforcement learning neural network control for uncertain nonlinear system with input saturation. *IEEE transactions on cybernetics*, 2019, pp. 3433-3443, doi:10.1109/TCYB.2019.2921057.
 19. Bhatia V., Kalaichelvi V., Karthikeyan R. Comparison of GA tuned fuzzy logic and NARMA-L2 controllers for motion control in 5-DOF robot. *Int. J. Comput. Appl.*, 2017, vol. 39, 2, pp. 69–78, doi: 10.1080/1206212X.2017.1281038.
 20. Fodor D., Six J, pp., and Diana D. Neural networks applied for induction motor speed sensorless estimation. *In Proc. ISIE'95*, 1995, pp. 181-186, doi: 10.1109/ISIE.1995.496623.
 21. George M. and Prasad Basu K. NARMA-L2 controlled variable frequency three-phase induction motor drive. *Eur. J. Sci. Res.*, 2012, vol.70, 1, pp. 98–111.

Відомості про авторів (About authors)

Воробійов Богдан Віталійович – доктор філософії, Національний технічний університет «Харківський політехнічний інститут», завідувач кафедри АЕМС; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-0264-354X>; e-mail: bohdan.vorobiov@khp.edu.ua.

Vorobiov Bohdan – Ph. D., National technical university "Kharkiv polytechnic institute", head of the department AEMS; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-0264-354X>; e-mail: bohdan.vorobiov@khp.edu.ua.

Сенченко Сергій Олександрович – Національний технічний університет «Харківський політехнічний інститут», аспірант кафедри АЕМС; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-0486-2471>; e-mail: Serhii.Senchenko@khp.edu.ua.

Senchenko Serhii –National technical university "Kharkiv polytechnic institute", postgraduate student of the department AEMS; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-0486-2471>; e-mail: Serhii.Senchenko@khp.edu.ua.

Рибаків Вадим Костянтинович – ВЛ ТОВ «ЦВВО», заступник керівника лабораторії; м. Харків, Україна; ORCID: <https://orcid.org/0009-0003-0713-5311>; e-mail: rybakov0905@gmail.com.

Rybakov Vadym – “CC Ex-EQUIPMENT” Ltd., deputy head of the laboratory; Kharkiv, Ukraine; ORCID: <https://orcid.org/0009-0003-0713-5311>; e-mail: rybakov0905@gmail.com.

Ліхно Ярослав Владленович – Національний технічний університет «Харківський політехнічний інститут», аспірант кафедри АЕМС; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-7082-7562>; e-mail: Yaroslav.Likhno@ieec.khp.edu.ua.

Likhno Yaroslav –National technical university "Kharkiv polytechnic institute", postgraduate student of the department AEMS; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-7082-7562>; e-mail: Yaroslav.Likhno@ieec.khp.edu.ua.

Хань Лю – Національний технічний університет «Харківський політехнічний інститут», аспірант кафедри АЕМС; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-8182-0040>; e-mail: seanhanzi@aliyun.com.

Khan Liu –National technical university "Kharkiv polytechnic institute", postgraduate student of the department AEMS; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-8182-0040>; e-mail: seanhanzi@aliyun.com.

Будь ласка, посилайтесь на цю статтю наступним чином:

Воробійов Б. В., Сенченко С. О., Рибаків В. К., Ліхно Я. В., Хань Л. Оптимізація вибору ступіня складності моделі двигуна постійного струму для системи з використанням нейронної мережі. *Вісник Національного технічного університету «ХПІ». Серія: Нові рішення в сучасних технологіях.* – Харків: НТУ «ХПІ». 2023. № 2 (16). С. 33-41. doi: 10.20998/2413-4295.2023.02.05.

Please cite this article as:

Vorobiov B., Senchenko S., Rybakov V., Likhno Y., Khan L. Optimization of the DC motor model complexity level selection for the system using a neural network. *Bulletin of the National Technical University "KhPI". Series: New solutions in modern technology.* – Kharkiv: NTU "KhPI", 2023, no. 2(16), pp. 33–41, doi:10.20998/2413-4295.2023.02.05.

*Надійшла (received) 28.03.2023
Прийнята (accepted) 02.05.2023*