

УДК 681.5.01.23

И.А. ОРЛОВСКИЙ (д-р техн. наук, доц.)
Запорожский национальный технический университет
i_orlovsky@mail.ru

ИСПОЛЬЗОВАНИЕ НЕЙРОКОНТРОЛЛЕРА С ПРОГНОЗИРОВАНИЕМ ДЛЯ УПРАВЛЕНИЯ ЭЛЕКТРОМЕХАНИЧЕСКИМ ОБЪЕКТОМ

Выполнено математическое описание прогнозирующего нейруправления. Описаны имеющиеся в системе MATLAB инструменты исследования прогнозирующего нейруправления, и с их использованием синтезирована система управления в контуре тока электропривода постоянного тока.

Ключевые слова: *нейронная сеть, нейруправление, функционал качества, алгоритм обучения, электромеханический объект, математическая модель с прогнозированием.*

Нейруправление динамическими (в том числе электромеханическими) объектами является новым перспективным управлением, находящемся на стыке таких дисциплин, как автоматическое управление, искусственный интеллект, нейрофизиология [1]. В литературе описаны многочисленные примеры практического применения нейронных сетей (НС) для решения задач управления различными объектами [2-5].

В настоящее время разработаны различные методы нейруправления, к которым относятся [1]: подражающее, инверсное, прогнозирующее, многомодульное, гибридное и вспомогательное. Достаточно часто [6, 7] для управления электромеханическими объектами применяют прогнозирующее нейруправление, однако исследований в Украине в этом направлении очень мало, автору известна только одна работа [7]. В ней авторы с использованием пакета прикладных программ Neural Network Toolbox системы Matlab исследовали методом моделирования возможность использования в контуре скорости нейроконтроллера с прогнозированием для наведения и стабилизации вооружения легкобронированных машин. Полученные в работе с использованием нейроконтроллера переходные процессы, по мнению авторов, имеют высокие динамические характеристики. Однако в работе отсутствует описание алгоритмов обучения нейроконтроллера и алгоритмов поиска управляющих сигналов. Не приведены параметры настройки нейроконтроллера.

Целью статьи является математическое описание прогнозирующего нейруправления и исследования методом математического моделирования его применения для управления электромеханическим объектом.

Структура основной части статьи состоит из пяти разделов. В первом разделе приводится общая характеристика метода прогнозирующего нейруправления. Во втором – основное математическое описание метода прогнозирующего нейруправления. В третьем – приведена структура нейроэмулятора. В четвертом – описаны имеющиеся в системе MATLAB инструменты исследования прогнозирующего нейруправления. В пятом – показаны результаты моделирования управления электромеханическим объектом.

Общая характеристика метода прогнозирующего нейруправления.

Обобщенное управление с прогнозированием (Generalized Predictive Control (GPC)), введенное Кларком и его коллегами в 1987 году [4, 5], относится к классу цифровых методов управления под названием «управление с прогнозированием по модели» (Model-Based Predictive Control). Методы прогнозирующего нейруправления проанализированы и успешно используются. Они могут учитывать в реальном времени ограничения объекта. Известно управление не минимально-фазовыми объектами, а также разомкнутых неустойчивых объектов и объектов с переменным или неизвестным мертвым (dead) временем. Методы также робастны к ошибкам параметров модели и шумам в датчиках.

Существуют рекомендации [3]: для нелинейной модели необходимо использовать нелинейный алгоритм оптимизации, при этом вычислительная эффективность и производительность определяется управляющими входами; для нелинейных объектов способность GPC выполнять более точный прогноз может быть повышена если НС «использует обучение динамики объекта вместо стандартных нелинейных технологий моделирования».

Выбор алгоритма минимизации влияет на его вычислительную эффективность. В [3], отмечается, что нейронный GPC (NGPC) алгоритм в режиме реального времени осуществлять сложно, из-за необходимости выполнения большого числа расчётов за короткий промежуток времени, поэтому очень мало работ рассматривают такое управление, а если и рассматривают, то для объектов с большими постоянными времени [3, 8]. При использовании Ньютона-Рафсона алгоритма оптимизации число итерационных преобразований значительно снижается по сравнению с другими методами. Авторы [3] (сотрудники исследовательского центра NASA США) утверждают, что по результатам моделирования, из-за снижения числа членов Гессииана, управление в реальном времени возможно.

Схема нейруправления с прогнозированием (NGPC) на основе модели состоит (рис. 1) из объекта управления, прямого нейроэмулятора объекта и оптимизационного модуля. Прямой нейроэмулятор используется для прогнозирования будущего поведения системы и вычисления ошибок. Иногда в схему на входе добавляется эталонная модель, которая определяет желаемый выход объекта.

© Орловский И.А., 2013

Алгоритм оптимизации определяет необходимые управляющие входы объекта для обеспечения заданного выхода с использованием критерия качества – стоимостной функции минимизации (Cost Function Minimization (CFM)).

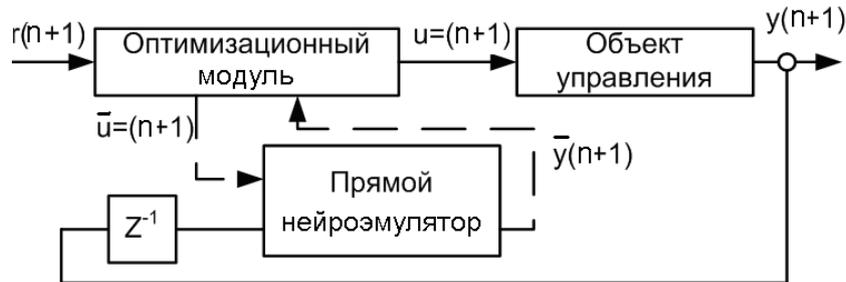


Рисунок 1 – Схема прогнозирующего нейроуправления на основе модели

Минусом систем прогнозирующего модельного нейроуправления [3] является невозможность их применения в системах с большой частотой дискретизации, так как оптимизационный алгоритм, работающий в режиме реального времени, за время одного такта не будет успевать находить наилучшую стратегию действий.

Математическое описание метода прогнозирующего модельного нейроуправления.

Для этого метода отсутствует обучаемый нейроконтроллер. Его место занимает оптимизационный модуль, работающий в режиме реального времени, в котором может быть использован симплекс-метод или квази-Ньютоновский алгоритм оптимизации [1].

Критерий качества управления. При прогнозирующем модельном нейроуправлении NGPC [1, 8] минимизируется критерий качества управления (функционал стоимости) интегральной ошибки, прогнозируемой на $N = \max(N_2, N_u)$ тактов вперед (при этом N_1, N_2, N_u задают пределы, внутри которых вычисляется ошибка слежения и мощность управляющего сигнала [8])

$$J(n) = \sum_{i=N_1}^{N_2} (\bar{y}_r(n+i) - \bar{y}_m(n+i))^2 + \rho \sum_{i=0}^{N_u} (\bar{u}(n+i) - \bar{u}(n+i-1))^2, \quad (1)$$

где N_1 и N_2 – минимальное и максимальное значения горизонта выходного сигнала, N_u – горизонт управления, \bar{y}_r и \bar{y}_m – желаемая и истинная реакция нейроэмулятора.

NGPC алгоритм основан на минимизации критерия качества управления (1) на конечном горизонте прогноза. Эта функция минимизирует затраты не только среднего квадрата ошибки между заданием сигнала и выходом модели объекта, но и квадрат скорости изменения управляющего входа $\bar{u}(n)$.

Есть четыре настроечные параметра N_1, N_2, N_u и ρ функционала качества. Единственное ограничение на значения N_u и N_1 в том, что они должны быть меньше или равны N_2 . Коэффициент ρ часто вносится под знак суммы и имеет разные значения для разной глубины прогнозирования. Существуют функционалы, в которых добавляются ещё слагаемые для ограничения значений управляющих сигналов [3].

Алгоритм минимизации критерия качества. Общая схема работы алгоритма следующая [9]. Оптимизационный модуль получает на такте n целевую траекторию на L тактов вперед, а если ее нет, то L раз дублирует значение текущей уставки $r(n+1)$ и использует это в качестве целевой траектории. Далее, для выбора оптимального управляющего воздействия, вычисления происходят во внутреннем цикле системы нейроуправления (его итерации обозначены как k). За время одного такта управления оптимизационный модуль подает на вход нейроэмулятора серию различных воздействий $\bar{u}(n+i, k)$ (где $0 \leq i \leq L-1, L$ – глубина прогнозирования), получает различные варианты поведения системы $\bar{y}(n+i+1, k)$, вычисляет критерий качества $J(n)$ по формуле (1) и определяет наилучшую стратегию управления $ST = \{\bar{u}(n, k_1) \bar{u}(n+1, k_2); \dots; \bar{u}(n+L-1, k_L)\}$ в смысле минимизации функционала (1). В итоге, на объект подается управляющий сигнал $\bar{u}(n, k_1)$. На следующем такте стратегия ST пересчитывается заново.

Для математической записи алгоритма напомним, что минимизация критерия (1) происходит по отношению к управляющему вектору $U = [\bar{u}(n+1), \bar{u}(n+2), \dots, \bar{u}(n+N_u)]^T$. Это достигается путем установки для критерия (1) Якобиана по управляющему вектору к нулю.

Поиск вектора U , минимизирующего функционал (1), осуществляется численным решением уравнения $J'(U) = 0$ в точке очередного приближения U . Согласно методу Ньютона [10], если точка приближения x^* «достаточно близка» к корню \bar{x} , и функционал $f(x)$ непрерывен, то алгоритм нахождения численного решения уравнения $f(x) = 0$ сводится к итерационной процедуре вычисления

$$x_{n+1} = x_n + \frac{f(x_n)}{f'(x_n)}.$$

С учетом того, что необходимо минимизировать значения функционала $J(U)$, т.е. необходимо найти корень для выражения его производной $J'(U) = 0$ относительно вектора U , итерационная процедура поиска записывается в следующем виде [3]:

$$U(k+1) = U(k) - \left(\frac{\delta^2 J}{\delta U^2}(k) \right)^{-1} \frac{\delta J}{\delta U}(k), \quad (2)$$

где $U(k) = [\bar{u}(n+1, k), \bar{u}(n+2, k), \dots, \bar{u}(n+N_u, k)]$, k – номер задающего набора.

Якобиан и Гессиан для задающего набора k определяются по выражениям

$$\frac{\delta J}{\delta U}(k) \equiv \begin{bmatrix} \frac{\delta J}{\delta \bar{u}(n+1)} \\ \dots \\ \frac{\delta J}{\delta \bar{u}(n+N_u)} \end{bmatrix}, \quad (3)$$

$$\frac{\delta^2 J}{\delta U^2}(k) \equiv \begin{bmatrix} \frac{\delta^2 J}{\delta \bar{u}(n+1)^2} & \dots & \frac{\delta^2 J}{\delta \bar{u}(n+1)\delta \bar{u}(n+N_u)} \\ \dots & \dots & \dots \\ \frac{\delta^2 J}{\delta \bar{u}(n+N_u)\delta \bar{u}(n+1)} & \dots & \frac{\delta^2 J}{\delta \bar{u}(n+N_u)^2} \end{bmatrix}. \quad (4)$$

Уравнение (2) прямо требует вычисления обратной матрицы Гессе. Этот процесс может потребовать больших вычислительных ресурсов. Одним из способов избежать использования обратной матрицы является использование разложения решения для входного вектора $U(k+1)$ [3]. Это осуществляется преобразованием уравнения (4) к виду системы линейных уравнений $Ax = b$

$$\frac{\delta^2 J}{\delta U^2}(k)(U(k+1) - U(k)) = -\frac{\delta J}{\delta U}(k),$$

где $A = \frac{\delta^2 J}{\delta U^2}(k)$, $b = -\frac{\delta J}{\delta U}(k)$, $x = (U(k+1) - U(k))$.

В таком виде уравнение (2) может быть решено с помощью программ решения системы линейных уравнений. После того, когда неизвестная величина x рассчитана, находится $U(k+1)$ по выражению $U(k+1) = x + U(k)$. Эта процедура повторяется, пока процентное изменение каждого элемента $U(k+1)$ меньше некоторого значения. Расчет каждого элемента Якобиана и Гессиана необходим для каждой итерации.

Структура нейроэмулятора.

В задачах нейроуправления для представления объекта управления используется, как правило, модель черного ящика [1], в котором наблюдаемыми являются текущие значения входа и выхода. Размерность вектора состояния объекта обычно считается известной. Динамика поведения объекта представляется в дискретном виде уравнениями в пространстве состояний

$$S(n+1) = \Phi(S(n), u(n)) \quad , \quad (5)$$

$$y(n+1) = \Psi(S(n)) \quad , \quad (6)$$

где $S(n) \in R^N$ – значение N -мерного вектора состояния объекта на n -м такте, $u(n) \in R^P$ – значение P -мерного вектора управления, $y(n+1) \in R^V$ – значение V -мерного выхода объекта управления на такте $n+1$.

На рис. 2 изображена структура нейроэмулятора, выполненного в виде рекуррентной многослойной прогнозирующей НС. Входы сети содержат управляющие сигналы в текущий и предыдущие моменты времени $u(n)$, ..., $u(n-N_{in})$ и сигналы обратной связи, поступающие с выхода на вход сети $y(n-1)$, ..., $y(n-N_{out}-1)$. В сети имеется один скрытый слой, содержащий нейроны с активационной функцией тангенс гиперболический. Выходной слой имеет один нейрон с линейной активационной функцией.

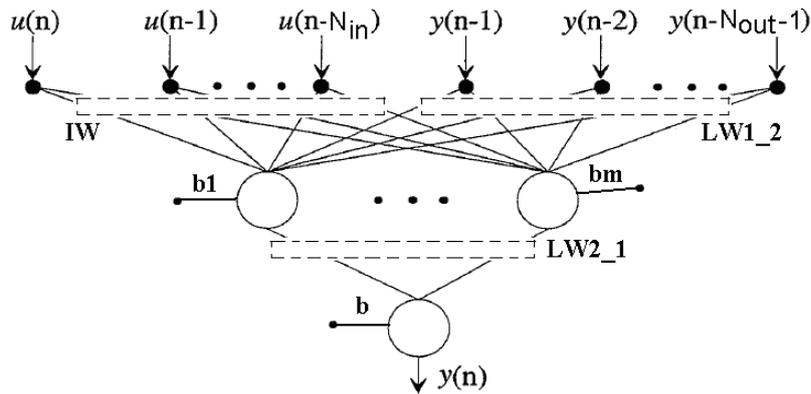


Рисунок 2 – Рекуррентная многослойная НС с прогнозированием

Выход сети вычисляется по следующим уравнениям:

$$y(n) = \sum_{j=1}^{hid} w_j f_j(net_j(n)) + b, \quad (7)$$

$$net_j(n) = \sum_{i=0}^{N_{in}} w_{j,i+1} u(n-i) + \sum_{i=1}^{N_{out}} w_{j,N_{in}+i+1} y(n-i) + b_j, \quad (8)$$

где $y(n)$ – выход НС в n -ом такте, $f_j(net_j(n))$ – активационная функция j -го узла скрытого слоя, $net_j(n)$ – сигнал на входе активационной функции j -го узла скрытого слоя, hid – число нейронов в скрытом слое, N_{in} – число задержанных управляющих входных сигналов, N_{out} – число входных сигналов, связанных с y , w_j , $w_{j,i}$ – весовые коэффициенты подключения j -го нейрона скрытого слоя с выходом и с i -ым входом соответственно, b_j , b – смещения на j -ом нейроне скрытого слоя и выходном нейроне.

Прогнозирование с помощью нейромультипликатора осуществляется рекурсивным расчётом выхода сети на несколько тактов вперёд путем сдвига во времени уравнений (7) и (8).

Инструменты исследования прогнозирующего нейрорегулятора в системе MATLAB.

В системе Matlab в пакете прикладных программ Neural Network Toolbox реализован для применения и исследования контроллер с предсказанием (NN Predictive Control (NPC)) [8]. Контроллер работает по описанному выше алгоритму. Используется функционал качества (1) для вычисления сигналов управления на заданном интервале времени. Имеется возможность использовать различные функции одномерной оптимизации и S-функции для вывода результатов.

Создан графический интерфейс, который руководит действиями пользователя для настройки контроллера. Имеется возможность задавать следующие параметры: размер скрытого слоя, такт дискретности съёма данных, количество элементов запаздывания для входных сигналов модели и сигналов обратной связи, нормализацию сигналов, длину обучающей выборки, максимальные и минимальные значения входного и выходного сигналов, максимальный и минимальный интервалы идентификации. Имеются возможности: импорта и экспорта обучающих данных; задания обучающей функции и количества циклов обучения; использования контрольного и тестового подмножеств; устанавливать параметры критерия качества N_1 , N_2 , N_u , ρ ; задания порога уменьшения показателя качества для алгоритма обучения; выбора процедуры одномерного поиска; задания числа итераций на один такт дискретности. В демонстрационном примере регулятор с предсказанием используется для управления каталитическим реактором с непрерывным перемешиванием.

Результаты моделирования.

Исследовалось методом моделирования применение контроллера с предсказанием для настройки контура тока в электроприводе с двигателем постоянного тока (рис. 3). Задавались следующие параметры контура тока: $K_V=178$; $T_p=0,0025$ с; $R_d=0,0091$ Ом; $T_d=0,037$ с; $K_t=0,00047$ В/А. Уменьшался в 5 раз коэффициент передачи контура по сравнению с задающей моделью (блок К, рис. 3).

Для создания обучающих данных использовалась задающая модель (рис. 4), в которой для управления применён ПИ-регулятор тока с $T_t=0,092$ с (удвоенное значение по сравнению с настройкой на модульный оптимум). Контур имел невысокое быстродействие, переходный процесс продолжался более 0,1 с (рис. 5). Обучающие данные формировались из случайных скачкообразно изменяющихся заданий с интервалом времени 0,1 с, в течение 50 с и шагом дискретизации сохранения данных $T_s=0,002$ с. Таким образом, каждая переменная имела 25001 измерение. Данные вводились в NPC с использованием опции «Import Data».

Для получения модели задавались: размер скрытого слоя равным 1; число задержек входных и выходных сигналов по две; обучение выполнялось с использованием контрольных и тестовых данных в течение 400 эпох,

ошибка обучения оставила $4 \cdot 10^{-7}$. После обучения весовые коэффициенты сети составили $LW1_2 = (-0,0182, 0,00567)$, $IW = (-7,43 \text{ e-}04, 7,266 \text{ e-}05)$, $LW2_1 = -77,46$, $b_1 = 0,617$, $b = 4,7793$.

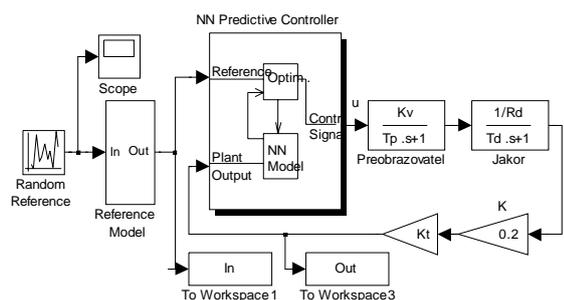


Рисунок 3 – Контур тока с NPC

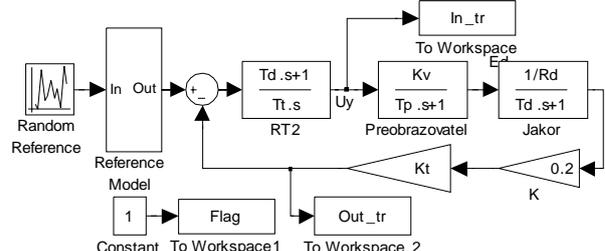


Рисунок 4 – Схема формирования обучающих данных

Для формирования управляющих сигналов в NPC задавались следующие настройки: $N_2 = 10$; $N_u = 4$; $\rho = 0,1$; $\alpha = 0,001$; Iteration Per Sample Time – 1; Minimization Routine – csrcbac. Проверка работы объекта с NPC осуществлялась заданием случайных скачкообразных сигналов. Из рис. 6 видно, что переходный процесс осуществлялся в 3-4 раза быстрее (в течение 0,03 с), при отсутствии перерегулирования.

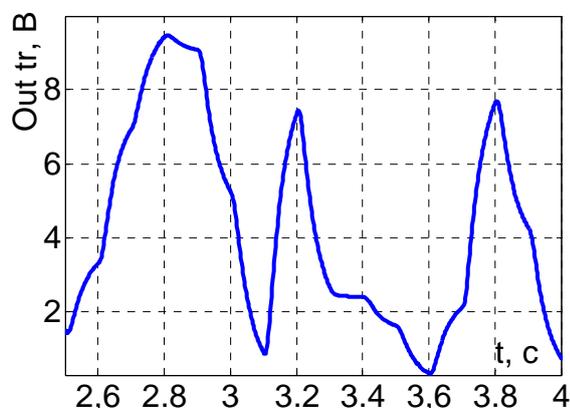


Рисунок 5 – Обучающие данные выхода объекта

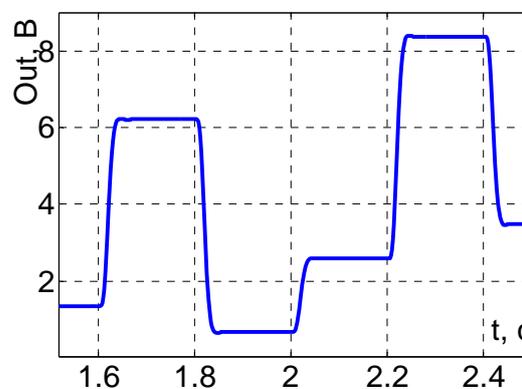


Рисунок 6 – Выход объекта с NPC

Выводы. Исследования методом математического моделирования NN Predictive Control на конкретном примере контура тока показало возможность получения высокой точности управления.

СПИСОК ЛИТЕРАТУРЫ

1. Чернодуб А. Н. Обзор методов нейруправления / А. Н. Чернодуб, Д. А. Дзюба. // Проблемы программирования. — 2011. — No 2. — С. 79-94.
2. Soloway D., Haley P.J. Neural Generalized Predictive Control // Proceedings of the IEEE International Symposium on Intelligent Control. — 18 September 1996. — 15. — P. 277—281.
3. Soloway D. Neural Generalized Predictive Control: A Newton-Raphson Implementation Langley Research Center / D. Soloway, P.J. Haley. - Hampton, Virginia. - February, 1997. - P. 17.
4. Clarke D. W., Generalized Predictive Control - Part 1: The Basic Algorithm / D. W. Clarke, C. Mohtadi and P. C. Tufts // Automatica. — 1987. - Volume 23. — Pp. 137-148.
5. Clarke D. W. Generalized Predictive Control - Part 2: The Basic Algorithm / D. W. Clarke, C. Mohtadi and P. C. Tufts // Automatica. — 1987. - Volume 23. — Pp. 149-163.
6. Gu D. Neural Predictive Control for a Car-like Mobile Robot / D. Gu and H. Hu. // International Journal of Robotics and Autonomous Systems. - May, 2002. - Vol. 39, No. 2-3.
7. Кузнецов Б. И. Синтез нейроконтроллера с предсказанием для двухмассовой электромеханической системы / Б. И. Кузнецов, Т. Е. Василец, А. А. Варфоломеев // Электротехника и электромеханика. — 2008. — Т. 3. — С. 27 — 32.
8. Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потёмкин. — М.: Диалог – МИФИ, 2002. — 496 с.
9. Википедия. Нейруправление [Электронный ресурс]. - Режим доступа: <http://ru.wikipedia.org>. — Загл. с экрана.
10. Википедия. Метод Ньютона [Электронный ресурс]. - Режим доступа: <http://ru.wikipedia.org>. — Загл. с экрана.

REFERENCES

1. A. N. Chernodub, D. A. Dzijuba. Obzor metodov nejroupravlenija // Problemy programmirovaniya. — 2011. — No 2. — pp. 79-94.
2. Soloway D., Haley P.J. Neural Generalized Predictive Control // Proceedings of the IEEE International Symposium on Intelligent Control. — 15 — 18 September 1996. — pp. 277—281.
3. Soloway D., Haley P.J. Neural Generalized Predictive Control: A Newton-Raphson Implementation Langley Research Center, Hampton, Virginia February 1997 P. 17.
4. D. W. Clarke, C. Mohtadi and P. C. Tufts, "Generalized Predictive Control - Part 1: The Basic Algorithm," Automatica, Volume 23, 1987, pp 137-148.
5. D. W. Clarke, C. Mohtadi and P. C. Tufts, "Generalized Predictive Control - Part 2: The Basic Algorithm," Automatica, Volume 23, 1987, pp 149-163.
6. D. Gu and H. Hu. Neural Predictive Control for a Car-like Mobile Robot // International Journal of Robotics and Autonomous Systems, Vol. 39, No. 2-3, May, 2002
7. Kuznecov B. I., Vasilec T. E., Varfolomeev A. A. Sintez nejrokontrollera s predskazaniem dlja dvuhmassovoj jelektromehaničeskoj sistemy //Jelektrotehnika i jelektromehanika. — 2008. — T. 3. — pp. 27 — 32.
8. Medvedev V.S. Nejronnye seti. MATLAB 6 / V.S. Medvedev, V.G. Potjomkin – M. : Dialog – MIFI, – 2002. – 496 p.
9. Vikipidija. Nejroupravlenie [Jelektronnyj resurs] : Rezhim dostupa : <http://ru.wikipedia.org>. – Zagl. s jekrana.
10. Vikipidija. Metod N'jutona [Jelektronnyj resurs] : Rezhim dostupa : <http://ru.wikipedia.org>. – Zagl. s jekrana.

Надійшла до редакції 23.02.2013

Рецензент: О.І. Толочко

I.A. ОРЛОВСЬКИЙ

Запорізький національний технічний університет

Використання нейроконтролера з прогнозуванням для керування електромеханічним об'єктом. Виконано математичний опис прогнозуючого нейрокерування. Описано наявні в системі MATLAB інструменти дослідження прогнозуючого нейрокерування, та з їх використанням синтезовано систему керування електромеханічного об'єкта.

Ключові слова: *нейронна мережа, нейрокерування, функціонал якості, алгоритм навчання, електромеханічний об'єкт, математична модель з прогнозуванням.*

I. ORLOVSKYI

Zaporizhzhya National Technical University

Application of Neural Controller with Forecasts to Control the Electromechanical Objects. On the basis of analysis of literary sources the urgency of further research in the field of Model-Based Neural Predictive Control is considered. Relevant is the application of these techniques to improve the management of electromechanical plants. Based on the analysis the objective of the article is: Neural Predictive Control mathematical description and study of methods of mathematical modeling of its application for the electromechanical facilities. The structure of the main part of the paper consists of five sections. The first section provides a general description of the method of Neural Predictive Control. The second is the basic mathematical description of the method of Neural Predictive Control. This section describes the criteria of quality management, which minimizes not only the values of the mean square error between the reference signal and the output of the model plant, but the rate of change and the square of the control input. It also provides an algorithm to minimize the quality criterion, using a pre-derived model of the plant in the form of a neural network. In the third - is the structure Neural emulator. The fourth - described the available tools in MATLAB Neural Control predictive studies. In the fifth - the results of modeling control electromechanical plant.

Key words: *neural network, neural controller, functional quality, learning algorithm, electromechanical plant, mathematical model of the prediction.*