

4. Степанов О.А., Амосов О.С. Нерекуррентное линейное оценивание с использованием нейронной сети // Математика, информатика, управление: Материалы III Всероссийской конф. – Иркутск. – 2004. – С.1–12.
5. Stepanov O. A., Amosov O.S. Optimal Estimation by Using Neural Networks. Proceeding of the 16-th IFAC World Congress. – Prague, Czech Republic, July 3-8, 2005.
6. Stepanov O.A., Amosov O.S. Nonrecurrent linear estimation and neural networks // Proceedings of IFAC Workshop on Adaptation and Learning in Control and Signal Processing (ALCOSP) and IFAC Workshop on Periodic Control Systems (PSYCO). – Yokohama, Japan, August 30 – September 1, 2004. – P. 213–218.
7. Amosov O. S. and L.N. Amosova. Optimal Estimation by Using Fuzzy Systems. In Proc. of the 17th IFAC World Congress. – Seoul, Korea, July 6–11, 2008.
8. Смоленцев Н.К. Основы теории вейвлетов. Вейвлеты в MATLAB. – М.: ДМК, 2005.
9. Дьяконов В.П. Вейвлеты. От теории к практике – М.: СОЛОН-Пресс, 2004.

Статья представлена к публикации членом редколлегии А.М. Шпилевым.

E-mail:

Амосов О.С. – aos@amgppgu.kms.ru.

УДК 681.5.01

© 2009 г. **К.В. Змеу**, канд. техн. наук,

Н.А. Марков,

И.А. Шипитько, канд. техн. наук

(Дальневосточный государственный технический университет, Владивосток),

Б.С. Ноткин, канд. техн. наук

(Институт автоматизации и процессов управления ДВО РАН, Владивосток)

БЕЗМОДЕЛЬНОЕ ПРОГНОЗИРУЮЩЕЕ ИНВЕРСНОЕ НЕЙРОУПРАВЛЕНИЕ С РЕГЕНЕРИРУЕМЫМ ЭТАЛОННЫМ ПЕРЕХОДНЫМ ПРОЦЕССОМ

Предложен новый подход к прогнозирующему инверсному нейроуправлению сложными нелинейными объектами, использующий регенерируемый на каждом шаге управления эталонный переходный процесс. Описан метод параметризации предложенной структуры. Обоснованность подхода подтверждена численным моделированием, а также результатами управления реальным объектом.

Ключевые слова: прогнозирующее инверсное нейроуправление, регенерируемый эталонный переходный процесс, быстропротекающие процессы.

Введение

Развивающийся стремительными темпами технический прогресс требует поиска новых решений в задачах управления промышленными объектами. Самая распространенная технология замкнутых систем управления – ПИД-регулирова-

ние – не всегда способна обеспечить достаточное качество управления нелинейными, слабо определенными, многосвязными объектами. Определенные надежды возлагаются на отличные от классических методы синтеза систем автоматического управления (САУ) промышленными объектами. Одним из таких подходов к синтезу САУ является прогнозирующее управление, именуемое в зарубежной литературе «Model-Based Predictive Control» (MPC) [1, 2].

Сущность MPC-подхода составляет следующая схема управления динамическими объектами [2, 3].

1. Рассматривается некоторая математическая модель объекта, начальными условиями для которой служит его текущее состояние.

2. На основании текущего значения управляемой переменной и значения задания генерируется траектория эталонного переходного процесса, переводящего объект из текущего состояния в заданное за конечный отрезок времени, именуемый горизонтом прогноза.

3. Выполняется оптимизация программного управления, целью которого служит приближение регулируемых переменных прогнозирующей модели к соответствующим задающим сигналам на горизонте прогноза.

4. На текущем интервале управления прикладывается первое значение из найденной оптимальной управляющей последовательности, реализуется найденное оптимальное управление и осуществляется измерение фактического состояния объекта на конец шага текущего интервала.

5. Горизонт прогноза сдвигается на шаг вперед, и повторяются пункты 1 – 4 данной последовательности действий.

Процедура оптимизации на шаге 3 требует значительных вычислительных ресурсов, поэтому до недавнего времени прогнозирующее управление использовалось для САУ с относительно большими постоянными времени, в основном в химической промышленности [4, 5]. Однако в последние годы наблюдается повышенный интерес к прогнозирующему управлению процессами с быстрой динамикой [6]. Так, в работе [3] предложен подход к синтезу нейросетевых систем прогнозирующего управления подобными системами.

Предложенный в [3] подход, названный безмодельным прогнозирующим инверсным нейроуправлением (ПИН), позволяет построить регулятор, реализующий и обобщающий необходимые примеры "вход-выход", непосредственно на основе данных "вход-выход" объекта управления (ОУ). Суть подхода состоит в том, что произвольные управляющие воздействия, приложенные к ОУ и переводящие его в некоторое новое состояние, рассматриваются как примеры целенаправленных управлений.

Концепция ПИН предполагает использовать в качестве прогнозирующего регулятора искусственную нейронную сеть (ИНС). Необходимая для ее обучения выборка формируется в соответствии со схемой, изображенной на рис. 1. Данный метод не предполагает применение математической модели в явном виде, что существенно облегчает использование ПИН в условиях неопределенности. Для получения прогнозирующей инверсной модели объекта путем обучения нейронной сети необходимы входной вектор P и целевой вектор T .

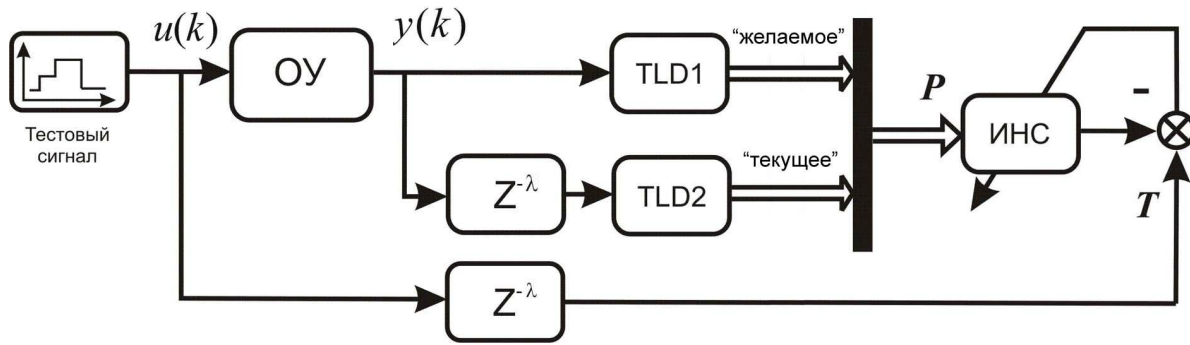


Рис. 1. Схема обучения прогнозирующего инверсного нейрорегулятора.

На рис. 1 блоки $Z^{-\lambda}$ обозначают задержку входного и выходного сигналов на горизонт прогноза λ , блоки TDL1 и TDL2 формируют регрессионные векторы, разнесенные между собой во времени на интервал горизонта прогноза.

Качество регулирования в системе ПИН существенно зависит от вида эталонного переходного процесса и способа его реализации при синтезе управления на каждом интервале дискретности переходного процесса. В традиционной системе MPC для этой цели может применяться принцип регенерируемого эталонного переходного процесса, который заключается в переопределении на каждом интервале управления формы желаемого переходного процесса. Рассмотрим возможность распространения этого принципа на схему прогнозирующего инверсного нейрорегулятора.

Структура регулятора

Структура предложенного регулятора приведена на рис. 2.

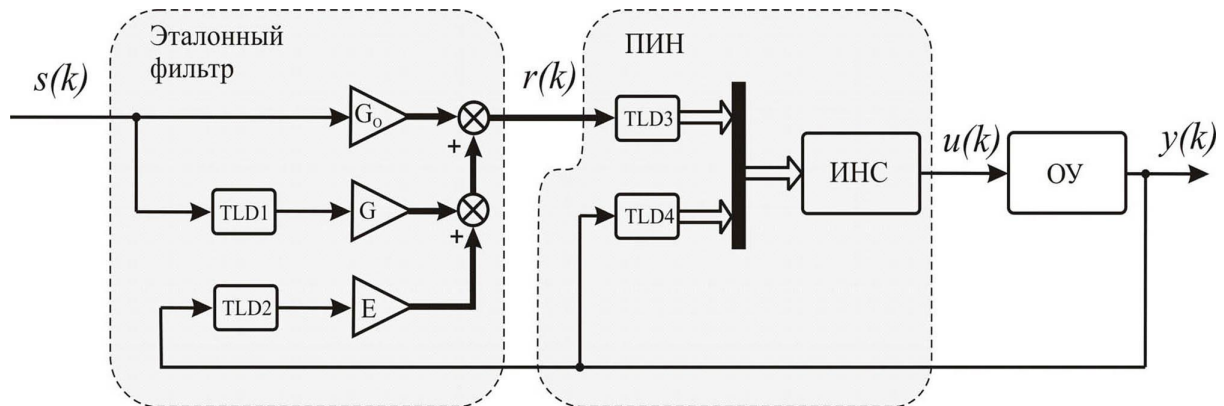


Рис. 2. Система прогнозирующего инверсного нейрорегулятора с регенерируемым эталонным процессом (ПИН-р).

На рис. 2 обозначены: $s(k)$ – сигнал задания; $r(k)$ – выход фильтра; $u(k)$ – текущее управление; $y(k)$ – выход объекта; G_0, G, E – матричные коэффициенты фильтра; TDL1-TDL4 – линии задержек; ИНС – искусственная нейронная сеть; ОУ – объект управления; ПИН – прогнозирующий инверсный нейрорегулятор.

Алгоритм работы регулятора, представленный на рис. 3, заключается в следующем. Эталонный фильтр, используя текущий выход объекта $y(i)$ и сигнал задания $s(k)$, в каждый момент управления генерирует эталонный переходный про-

цесс $r(i)$. Прогнозирующий инверсный нейрорегулятор на основе эталонной траектории $r(i)$ формирует управляющее воздействие $u(i)$. Количество задержек в блоках $TDL1$ и $TDL2$ определяется порядком эталонного фильтра, в блоках $TDL3$ и $TDL4$ – размерностью регрессионного вектора, обозначенной как ND .




Рис. 3. Временные диаграммы, иллюстрирующие алгоритм работы ПИН-р.

Массив данных при обучении нейронной сети (рис. 1) образован набором векторов

$$P = [y(k), y(k-1), \dots, y(k-ND), y(k-\lambda), \dots, y(k-\lambda-ND)],$$

$$T = [u(k-\lambda)].$$

При использовании обученной сети в качестве регулятора (рис.1) на ее вход подается вектор сигналов вида

$$P = [r(k), r(k-1), \dots, r(k-ND), y(k), y(k-1), \dots, y(k-\lambda)].$$

Вектор сигналов $r(k) \dots r(k-ND)$ представляет собой последние ND значений спрогнозированной эталонной траектории.

Алгоритм работы эталонного фильтра

Рассмотрим предлагаемую методику на примере эталонного фильтра второго порядка, заданного непрерывной передаточной функцией (1)

$$W(s) = \frac{r(s)}{s(s)} = \frac{I}{T^2 s^2 + 2\xi Ts + I}, \quad (1)$$

где $s(s)$, $r(s)$ – изображения соответственно задающего (входного) и эталонного (выходного) сигналов фильтра.

Перейдем от непрерывной передаточной функции (1) к дискретной

$$W(z) = \frac{r(z)}{s(z)} = \frac{b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}}, \quad (2)$$

где b_1, b_2, a_1, a_2 – коэффициенты числителя и знаменателя соответственно, z – оператор z -преобразования.

Используя полученную дискретную функцию, запишем разностное уравнение

$$b_1 \cdot s(k-1) + b_2 \cdot s(k-2) = r(k) + a_1 \cdot r(k-1) + a_2 \cdot r(k-2). \quad (3)$$

Прямая модель динамики фильтра имеет вид

$$\begin{aligned} r(k) &= b_1 \cdot s(k-1) + b_2 \cdot s(k-2) - a_1 \cdot r(k-1) - a_2 \cdot r(k-2) = \\ &= \sum_{i=1}^n b_i \cdot s(k-i) - \sum_{i=1}^m a_i \cdot r(k-i), \end{aligned} \quad (4)$$

где i – текущий интервал дискретности.

Прогнозирующую модель, соответствующую (3), можно переписать в форме:

$$r(k+j) = \sum_{i=2}^n g^{(j)}_i \cdot s(k-i+1) + \sum_{i=1}^m e^{(j)}_i \cdot r(k-i+1) + \sum_{i=0}^{j-1} g^{(j-i)}_1 \cdot s(k+i), \quad (5)$$

где $j = 1, 2, \dots, \lambda$; λ – горизонт прогноза; $g^{(j)}_i$ и $e^{(j)}_i$ – коэффициенты, полученные на основании параметров b_i и a_i с использованием следующих рекуррентных алгоритмов:

$$\begin{aligned} e^{(j)}_i &= e^{(j-1)}_1 \cdot a_i + e^{(j-1)}_{i+1}, \\ i &= 1, \dots, m, \quad j = 2, \dots, \lambda, \\ g^{(j)}_i &= e^{(j-1)}_1 \cdot b_i + g^{(j-1)}_{i+1}, \\ i &= 1, \dots, n, \quad j = 2, \dots, \lambda, \end{aligned} \quad (6)$$

при этом

$$\begin{aligned} e^{(1)}_i &= a_i, \quad i = 1, \dots, m, \\ g^{(1)}_i &= b_i, \quad i = 1, \dots, n. \end{aligned}$$

Для уменьшения количества неизвестных в прогнозирующей модели принято допущение о постоянстве сигнала задания в пределах горизонта прогноза по аналогии с [7]:

$$s(k) = s(k+1) = \dots = s(k+\lambda-1), \quad (7)$$

тогда прогнозирующая модель для $j=\lambda$ принимает вид

$$r(k+\lambda) = \sum_{i=2}^n g^{(\lambda)}_i \cdot s(k-i+1) + \sum_{i=1}^m e^{(\lambda)}_i \cdot r(k-i+1) + h(\lambda) \cdot s(k), \quad (8)$$

где

$$h(\lambda) = g^{(\lambda)}_1 + g^{(\lambda-1)}_1 + \dots + g^{(1)}_1.$$

Поскольку генерируемый эталонный переходный процесс – продолжение фактической траектории выхода объекта, а модель (8) является рекуррентной, то на текущем и предшествующих интервалах управления эталонный сигнал $r(k)$ заменяем фактическим выходом объекта $y(k)$

$$r(k+\lambda) = \sum_{i=2}^n g^{(\lambda)}_i \cdot s(k-i+1) + \sum_{i=1}^m e^{(\lambda)}_i \cdot y(k-i+1) + h(\lambda) \cdot s(k). \quad (9)$$

Набор из λ уравнений может быть записан в матричной форме

$$R = GS_k + EY_k + G_0S, \quad (10)$$

где

$$E = \begin{pmatrix} e^{(1)}_1 & e^{(1)}_2 & \dots & e^{(1)}_m \\ e^{(2)}_1 & e^{(2)}_2 & \dots & e^{(2)}_m \\ \dots & \dots & \dots & \dots \\ e^{(\lambda)}_1 & e^{(\lambda)}_2 & \dots & e^{(\lambda)}_m \end{pmatrix}, G = \begin{pmatrix} g^{(1)}_1 & g^{(1)}_2 & \dots & g^{(1)}_n \\ g^{(2)}_1 & g^{(2)}_2 & \dots & g^{(2)}_n \\ \dots & \dots & \dots & \dots \\ g^{(\lambda)}_1 & g^{(\lambda)}_2 & \dots & g^{(\lambda)}_n \end{pmatrix}, G_0 = \begin{pmatrix} h(1) \\ h(2) \\ \dots \\ h(\lambda) \end{pmatrix}. \quad (11)$$

Численные эксперименты

Управление пневмоцилиндром. В качестве одного из объектов управления использовалась модель пневмоцилиндра, описанная в [8], блок-схема которой изображена на рис. 4а.

Пневмоцилиндр как объект управления интересен прежде всего высоким порядком. К тому же он относится к объектам с быстрой динамикой.

В момент времени $t = 4$ с (рис. 4б) нагрузка на штоке была увеличена на 20%. Эксперимент показал, что ПИН-р – регулирование дает существенное преимущество во времени регулирования, практически не уступая ПИД-управлению в перерегулировании, что особенно важно для позиционных систем, каковой является пневмоцилиндр.

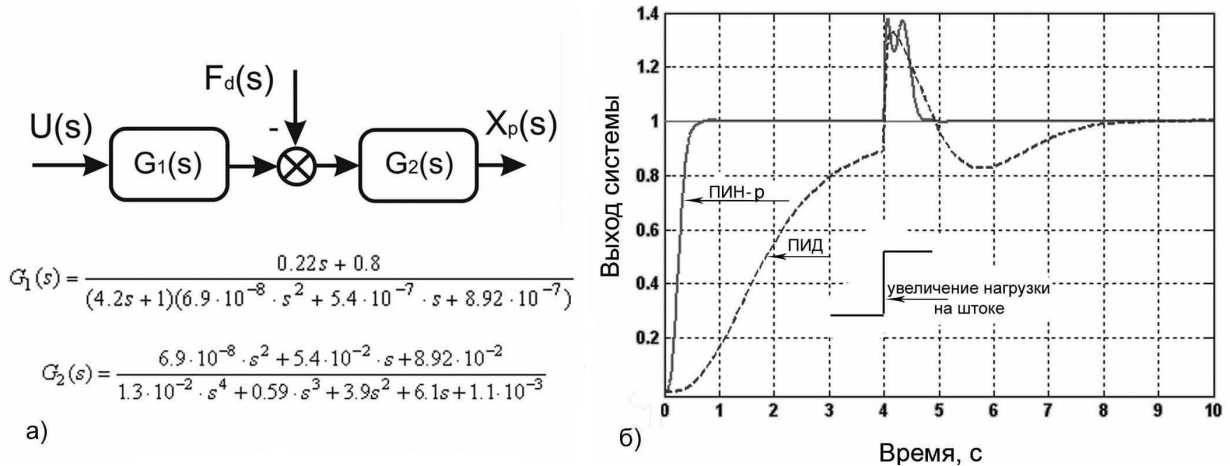


Рис. 4. а) блок-схема математической модели пневмоцилиндра;
б) результаты управления моделью пневмоцилиндра.

Управление углом азимута лабораторной установки SE-150 «Helicopter Model». Фирма Numusoft (Чехия) [9] разработала лабораторную установку SE-150, выполненную в форме вертолета, в которой предусмотрено управление по двум координатам: углу азимута и углу атаки.

Внешний вид установки представлен на рис. 5а. Модель состоит из корпуса, стилизованного под вертолет, на котором крепятся два двигателя постоянного тока, с насаженными на вал лопастями.

На рис. 5б представлена структурная схема математической модели угла азимута. Согласно схеме напряжение u_2 , поступающее на двигатель постоянного

тока, преобразуется в угол поворота установки φ . Полное математическое описание установки доступно на Интернет-сайте [10].




Рис. 5. а) внешний вид установки;
б) структурная схема упрощенной нелинейной математической модели (угол азимута).

Лабораторная установка *CE-150* представляет интерес с точки зрения управления как нелинейный и статически неустойчивый объект с быстрой динамикой. Управление осложняется также наличием измерительного шума в каналах обратной связи. В данной работе приведены результаты управления нелинейной моделью угла азимута.

В предложенной схеме управления (рис. 2) можно выделить несколько настроечных параметров: порядок эталонного фильтра, длина горизонта прогноза, постоянная времени фильтра. Покажем влияние этих параметров на качество управления серией следующих экспериментов.




Рис. 6. Переходный процесс: а) для различных эталонных фильтров: 1 – фильтр первого порядка; 2 – второго порядка; б) для различных значений длины горизонта.

На рис. 6а сплошной линией обозначен выход системы, пунктирной – переходная характеристика передаточной функции, положенной в основу фильтра. Эксперименты показали, что использование фильтра второго порядка в данном случае дает более качественный переходный процесс. Возможно применение фильтров более высокого порядка, но на качестве управления это скажется не лучшим образом. Изменяя длину горизонта прогноза λ , можно регулировать время переходного процесса и уменьшать колебательность системы. С увеличением постоянной времени эталонного фильтра T_ϕ (рис. 7а, фильтр первого порядка) ко-

лебательность системы уменьшается, однако время регулирования в этом случае увеличивается.

Цель следующего эксперимента – не столько демонстрация работоспособности предложенного метода, сколько его конкурентоспособности перед традиционными подходами, в частности ПИД-регулированием. На рис. 7б приведены результаты работы трех систем, из которых наилучшим образом проявил себя ПИН-р регулятор.

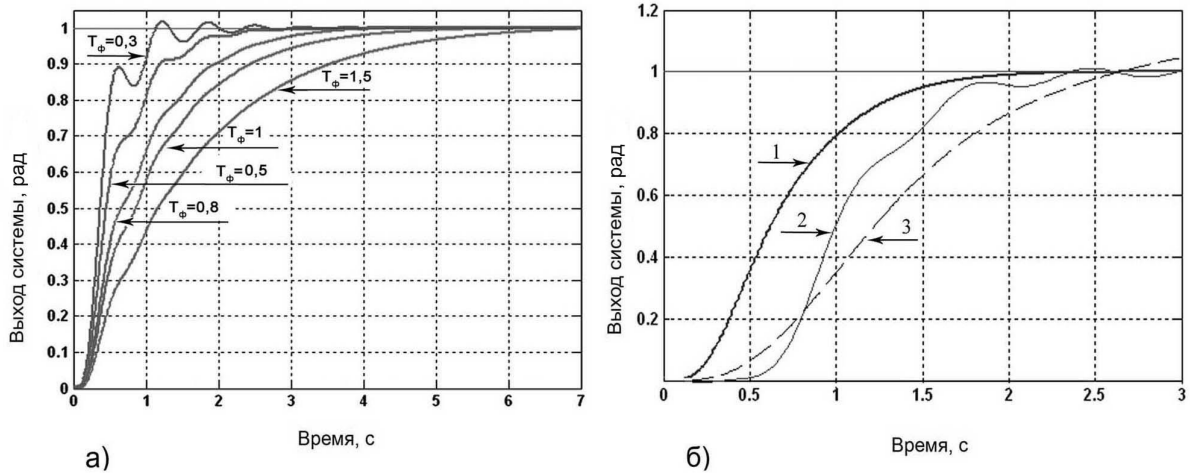


Рис. 7. Переходные процессы: а) для различных значений постоянной времени эталонного фильтра; б) для сравнения трех систем: 1 – ПИН-р; 2 – ПИН; 3 – ПИД.

Натурные эксперименты

Эксперименты по управлению лабораторной установкой *CE -150 «Helicopter Model»* проводились при помощи Интернет-ресурса [10]. Результаты управления приведены на рис. 8.




Рис. 8. Результаты управления с ПИД и ПИН-р.

Для обеспечения необходимого качества регулирования настройка регулятора проводилась в два этапа. На первом был обучен и настроен ПИН-р регулятор. Вторым этапом стало устранение статической ошибки. Для компенсации статической ошибки в структуру регулятора перед эталонным фильтром был введен

статический элемент с нелинейной характеристикой, обратный статической характеристике замкнутого контура управления. Для демонстрации конкурентоспособности предложенной системы приведен фрагмент рейтинговой таблицы сайта АСТ с результатами двух систем управления – ПИД и ПИН-р (таблица).

Рейтинг	Тип контроллера	Время регулирования, с	Перерегулирование, %
6	ПИН-р	3.550	0.000
8	ПИД	3.960	-0.352

Заключение

В работе предложены структура прогнозирующего инверсного нейрорегулятора с регенерируемым эталонным переходным процессом, а также способ его параметризации. Разработана дискретная модель регулятора, пригодная для реализации с использованием цифровых микропроцессорных систем.

Результаты численных и натуральных экспериментов демонстрируют преимущество ПИН-р перед системами, построенными на основе классического ПИД-регулирования, при управлении нелинейными быстропротекающими процессами. Стоит также отметить, что приемы ПИН и ПИН-р регулирования не требуют априорного знания математической модели объекта, которая используется в подобных системах в неявном виде. Это позволяет применять описанные подходы в условиях неопределенности. Предложенный метод не требует численной оптимизации в реальном времени и, следовательно, больших вычислительных ресурсов, что особенно важно для объектов с быстрой динамикой.

ЛИТЕРАТУРА

1. *Camacho E.F., Bordons C.* Model Predictive Control. – Springer, 1999.
2. *Maciejowski J.M.* Predictive control with constraints. – Prentice Hall, 2002.
3. *Змеу К.В., Ноткин Б.С., Дьяченко П.А.* Безмодельное прогнозирующее нейрорегулирование. // Мехатроника, автоматизация, управление. – 2006. – № 9. – С. 8-15.
4. *Wang Dianhui.* Adaptive Neural Model Predictive Control of Chemical Process: An Empirical Study – Institute of Intelligent Control, Dalian Maritime University. – China, 1999.
5. Neural networks based model predictive control of an industrial polypropylene process. Jianli Wei, Yjngmao Xu, and Jie Zhang // Proceedings of the 2002 IEEE International Conference on Control Applications. – Glasgow. – September 18-20, 2002.
6. Neural Networks for Modeling and Control of Dynamic Systems // Norgaard, M., Ravn O., Poulsen N.K., Hansen L. K. – Springer-Verlag: London, 2000.
7. *Martin Sanchez, Jose Rodellar.* Adaptive predictive control: From the concepts to plant optimization. – Prentice Hall PTR, 1996. – P.352.
8. *Karpenko M., Sepehri N.* QFT design of a PI controller with dynamic pressure feedback for positioning a pneumatic actuator // In Proceedings of the 2004 American Control Conference. – Boston, MA, 2004. – P.5084–5089.
9. Официальный сайт компании Humusoft [Электронный ресурс] – Режим доступа: <http://www.humusoft.com>.
10. Automatic Control Telelab [Электронный ресурс] – Режим доступа: <http://www.dii.unisi.it/~control/act/home.php>.

Статья представлена к публикации членом редколлегии Е.А. Ереминым.

E-mail:

Змеу К.В. – k.zmeu@ieee.org.