

TATUR M.M. Prospects and problems of Byelorussian mobile robotic systems creating

In the work the project to create one of the first domestic mobile robotic systems designed for mass production and industrial application is announced. Scientific, technical and organizational obstacles for such projects implementation are noted.

УДК 004.89

Иванюк Д.С.

НЕЙРО-ПИД-РЕГУЛЯТОР ПОУ

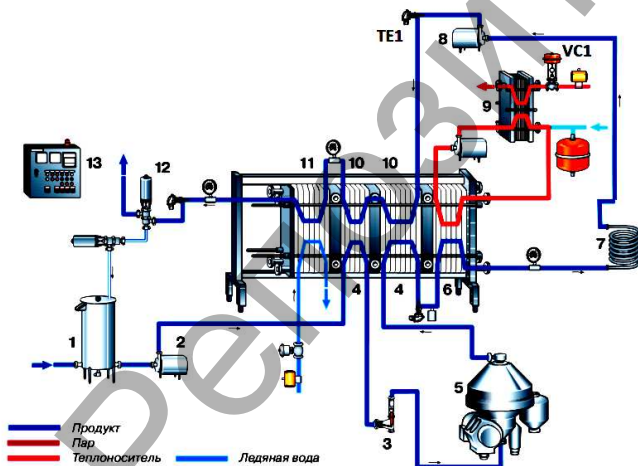
Введение. К концу XIX века тепловая обработка молока получила столь широкое применение, что стала использоваться для разных целей на большинстве молокозаводов – например, для обработки молока при изготовлении сыра и масла. До внедрения тепловой обработки молоко представляло собой постоянный источник инфекций, так как оно является идеальной средой для развития микроорганизмов. Через молоко зачастую распространялись такие болезни, как туберкулез и брюшной тиф.

В термине “пастеризация” запечатлено имя Луи Пастера, который в середине XIX века провел фундаментальные исследования воздействия тепла на микроорганизмы, приводящего к их гибели, и возможности применения температурной обработки для консервирования пищевых продуктов.

Пастеризация молока – это особый вид тепловой обработки, который можно определить как “любую тепловую обработку молока, обеспечивающую безусловное уничтожение микроорганизмов – возбудителей туберкулеза, не вызывая при этом значительных изменений физических и химических качеств молока” [1].

Пластинчатая пастеризационно-охладительная установка (ПОУ) предназначена для тепловой обработки и охлаждения молочных продуктов в непрерывном тонкослойном закрытом потоке. Схема типовой пастеризационной установки приведена ниже (рис. 1). Нагрев осуществляется за счет подачи пара через управляемый клапан VC1. Диапазон работы управляемых паровых клапанов от 0% – полностью закрыт, до 100% – полностью открыт. Температура ТЕ1 поддерживается в пределах 92±2 °С.

Современная ПОУ, включающая оборудование для эксплуатации, надзора и управления процессом, собирается из согласованных компонентов, образуя сложный технологический агрегат. Для автоматизации регулирования температурного режима в состав ПОУ входит система управления на базе промышленного контроллера. От применяемых алгоритмов управления напрямую зависит качество получаемой продукции.



1. балансный танк; 2. подающий насос; 3. регулятор потока; 4. секции регенеративного предварительного подогрева; 5. центробежный очиститель; 6. секцию нагрева; 7. трубу выдержки; 8. вспомогательный насос; 9. систему нагрева горячей воды; 10. секции регенеративного охлаждения; 11. секции охлаждения; 12. клапан возвратный; 13. панель управления

Рис. 1. Схема и общий вид пастеризационной установки

Иванюк Дмитрий Сергеевич, старший преподаватель кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Физика, математика, информатика

Пастеризационные установки как объект автоматизации

Рассмотрим подробно секцию нагрева ПОУ. Входные и выходные параметры и возмущающие воздействия для нее представлены на рис. 2.




Рис. 2. Структурная схема секции нагрева ПОУ как объекта автоматизации

Основными причинами, вызывающими колебания температуры t_{mn} нагревания молока являются непостоянство расхода G_m продукта, непостоянство температуры t_0 исходного молока, изменение расхода G_n пара, обусловленное колебания его давления p_n , изменение коэффициента теплопередачи K вследствие отложения белка молока на теплопередающих поверхностях [2].

Для стабилизации температуры t_{mn} нагревания молока в качестве управляющего воздействия в основном применяют расход пара G_n . Его регулируют посредством управляемого клапана (VC1 на рис. 1).

Статические и динамические характеристики большинства ПОУ в настоящее время экспериментально и аналитически выявлены. Для нагревательной части по каналу $G_n \rightarrow t_{mn}$, т.е. зависимость

$t_{mn} = f(G_n)$ определяется из уравнения теплового баланса секции пастеризации и систем обогрева горячей воды. Если пренебречь потерями тепла в окружающую среду, то уравнение теплового баланса в установившемся режиме имеет вид:

$$G_m c_m (1 - \varepsilon)(t_{mn} - t_0) = G_n (i - c_k t_k),$$

где t_k – температура конденсата °С; c_m , c_k – теплоемкость соответственно молока и конденсата, Дж/(кг·°С); ε – коэффициент регенерации тепла установки; i – энтальпия пара, Дж/кг. После преобразования данного уравнения получаем статическую характеристику нагревательной части установки:

$$t_{mn} = t_0 + \frac{i - c_k t_k}{G_m c_m (1 - \varepsilon)} G_n.$$

Результаты экспериментальных и теоретических исследований показали, что динамическая характеристика нагревательной части установки по каналу «расход пара – температура нагрева молока» может быть выражена передаточной функцией

$$W(p) = \frac{K_n e^{-p\tau_s}}{Tp + 1}, \tag{1}$$

где K_n – коэффициент передачи объекта, °С/(кг/с),

$$K_n = \frac{i - c_k t_k}{G_m c_m (1 - \varepsilon)}, \quad (2)$$

где T – постоянная времени объекта, с; τ_z – время запаздывания, с; p – комплексная переменная (оператор Лапласа).

Таким образом, передаточная функция нагревательной части установки характеризуется последовательно соединенными апериодическим звеном первого порядка и звеном транспортного запаздывания. В таблице 1 приведены средние значения параметров некоторых ПОУ.

Таблица 1

Установка	$K_n, \text{ } ^\circ\text{C}/(\text{кг}/\text{с})$	$T, \text{ с}$	$\tau_z, \text{ с}$
ОПУ-5М	2300	369	12
ОПУ-10	1150	190	7
ОПУ-25	525	450	4

При накоплении белковых веществ на теплопередающих поверхностях значения T в среднем возрастают на 50–60%.

Современные подходы адаптивного управления. Нечеткая логика, нейруправление и оптимальное управление в настоящее время являются глубоко проработанными и успешно применяемыми подходами для эффективного решения многих реальных производственных задач управления [4, 5]. Рост исследований в области нейруправления произошел после 1987 года, когда в Сан-Диего была проведена первая IEEE конференция по нейронным сетям. На данном мероприятии было предложено большое количество нейросетевых систем управления.

Однако нейросетевые подходы имеют целый ряд серьезных недостатков. Физический смысл полученной нейронной сети, которая осуществляет управление, не является четким для понимания (особенно для инженеров по автоматизации). Также возникают вопросы об устойчивости такой системы управления. Поэтому в настоящее время даже несмотря на их недостатки ПИД-регуляторы наиболее широко распространены. Они требуют экспертной настройки при запуске системы, более того во время работы из-за изменяющихся внешних условий их также необходимо подстраивать для получения наилучшего результата. ПИД-регуляторы плохо подходят для управления нелинейными системами, для условий быстро меняющихся параметров объекта управления и очень требовательных к точности управления систем.

Одной из современных разработок в данной области является управление на основе долгосрочного прогнозирования (рис. 3). Стратегия метода состоит в том, что в каждый конкретный момент времени t делается прогноз выхода процесса на длительный временной горизонт. Этот прогноз, основанный на математической модели процесса,

делается явно или подразумевается в алгоритме управления.

Кроме всего прочего, прогноз зависит от сценария управления в будущем, которое предполагается постоянным на все время прогнозирования. Из нескольких сценариев управления выбирается стратегия, обеспечивающая сходимость выходного процесса к желаемому (установке) наилучшим образом. Стратегия, выбранная в качестве наилучшей, применяется затем в качестве управляющего воздействия к реальному процессу, однако только на заданное время. В следующий момент дискретного времени вся процедура повторяется, в результате чего обеспечивается уточненное управляющее действие. Такая стратегия известна под названием стратегии управления по удаляющемуся горизонту.

В настоящее время существует большое количество подходов к нейросетевому управлению. Согласно [4] можно выделить:

- Последовательная схема управления. Нейронная сеть непосредственно обучается отображению желаемых (опорных) сигналов в управляющие воздействия, необходимые для получения таких сигналов.
 - Параллельная схема управления. Нейронная схема используется для компенсации управляющего воздействия, задаваемого обычным контроллером. Компенсация производится таким образом, чтобы выходной сигнал объекта управления поддерживался как можно ближе к желаемому.
 - Схема управления с самонастройкой. Нейронная сеть настраивает параметры управления, задающие работу обычного контроллера, таким образом, чтобы выходной сигнал объекта управления поддерживался как можно ближе к желаемому.
 - Схема управления с эмулятором и контроллером (схема обратного распространения во времени). В этом случае максимизируется некоторая мера полезности или эффективности во времени.
 - Адаптивно-критическая схема. Эта схема приближена к динамическому программированию, т.е. реализации оптимального управления во времени в условиях шумов и нелинейностей.
- Рассмотрим более подробно данные подходы к нейросетевому управлению.

Последовательная схема управления. Данная схема наиболее проста, что является как основным достоинством (несмотря на относительную простоту, подходит для решения широкого круга задач), так и недостатком (требует переобучения при изменении параметров объекта управления). Рис. 4 отражает данную схему.

Схема обратного распространения во времени. «Обратное распространение во времени» – одна из важных архитектур нейронного управления, использующая алгоритм обратного распространения ошибки. В этой схеме для управления объектом используется две нейронные сети (рис. 5).




Рис. 3. Стратегия управления на основе долгосрочного прогнозирования




Рис. 4. Последовательная схема нейронного управления

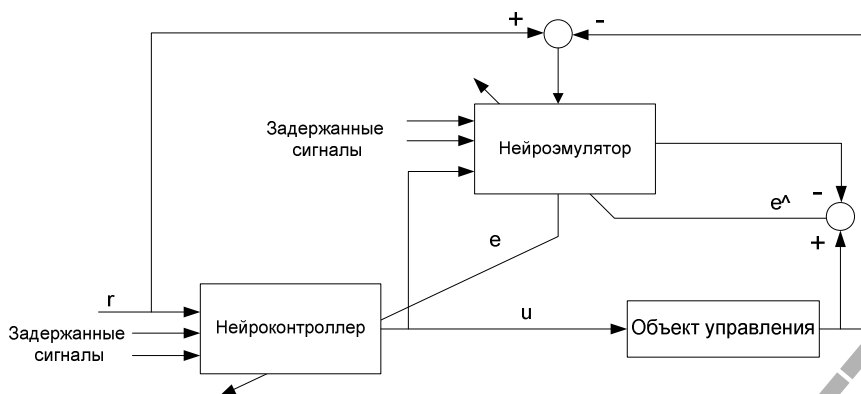


Рис. 5. Схема нейронного обучения с эмулятором и контроллером




Рис. 6. Адаптивно-критическая схема

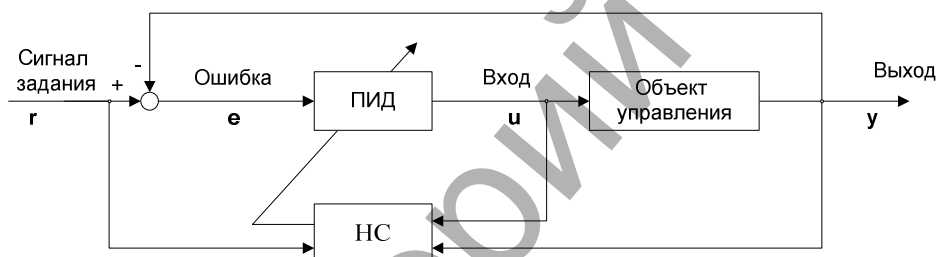


Рис. 7. Общая схема нейро-ПИД регулятора

Первая сеть используется как эмулятор, вторая – как контроллер. Сеть эмулятор может обучаться автономно, с использованием архитектуры обобщенного управления, или даже непосредственно, путем ввода случайных входных сигналов для обучения динамике объекта управления.

Адаптивно-критическая схема. Рассматривая подходы к обучению нейросетей, можно отдельно выделить «обучение с подкреплением» (Reinforcement Learning) или «обучение с критикой». Необходимость применения данной парадигмы возникает в тех случаях, когда известна конечная цель, но неизвестен способ ее достижения. Это тот случай, когда желаемый отклик системы неизвестен, однако может быть дана некоторая оценка ее работы. Такая оценка обычно имеет вид скалярного «подкрепляющего» сигнала. В случае успеха он положителен, при неудаче отрицателен, а в нейтральных случаях равен нулю. Таким образом, можно поощрять за приближение к цели и наказывать за удаление от нее или за медлительность, причем поощрение может быть запаздывающим. Одной из областей применения «обучения с подкреплением» является область задач управления, когда желаемое управление на входе динамического объекта неизвестно, в то время как заметить отклонение его выхода за допустимые пределы несложно. Методы обучения с подкреплением относятся к разряду методов динамического программирования, но без модели объекта. Общая схема приведена на рис. 6.

ПИД-регулятор с самонастройкой. ПИД-регулятор может быть подстроен во время работы за счет изменения его коэффициентов. Существует большое количество схем таких самонастраивающихся ПИД-регуляторов. В данной схеме для настройки коэффициентов используется нейронная сеть (НС).

Такие нейро-ПИД регуляторы в настоящее время используются для построения различных систем управления. Рис. 7 поясняет базовые идеи данного подхода.

В большинстве работа для «тонкой» подстройки ПИД используется многослойный персептрон (MLP) [6, 7]. Также используются рекуррентные или RBF нейронные сети. Современные подходы основываются на интеграции различных подходов – нечеткой логики, классических подходов и т.д. [8].

Для обучения НС обычно используется алгоритм обратного распространения ошибки (BP algorithm) [5] или его модификации. Для поиска начальных значений порогов и весовых коэффициентов Сигеру Омату [5] предложил использовать генетические алгоритмы (GA). Для симуляции систем управления широко применяются пакеты MATLAB и Simulink, в некоторых работах можно встретить реализацию в качестве программного модуля для персонального компьютера (PC).

Разработанный нейро-ПИД регулятор ПОУ. Общая структура самонастраивающегося нейро-ПИД регулятора показана на рис. 8, где выходы нейронной сети – пропорциональный (K_P), интегральный (K_I) и дифференциальный (K_D) коэффициенты.

Для построения модели нейро-ПИД регулятора опишем алгоритм функционирования и обучения нейронной сети [8].

Обобщенное дельта правило для сигмоидной функции активации нейронных элементов. Выходное значение j -го нейронного элемента определяется следующим образом:

$$y_j = \frac{1}{1 + e^{-s_j}}, \quad s_j = \sum_i \omega_{ij} y_i - T_j.$$

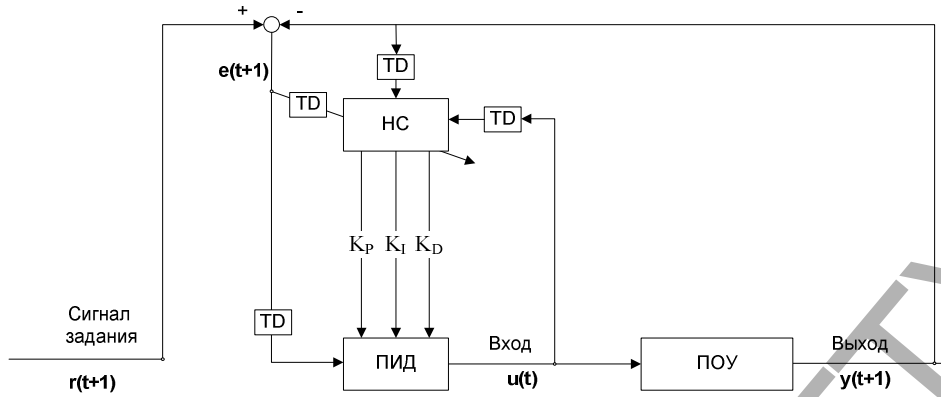


Рис. 8. Нейро-ПИД регулятор, TD означает оператор задержки

Обобщенное дельта правило для сигмоидной функции активации:

$$\omega_{ij}(t+1) = \omega_{ij}(t) - \alpha \gamma_j y_j (1 - y_j) y_i,$$

$$T_j(t+1) = T_j + \alpha \gamma_j y_j (1 - y_j).$$

Ошибка для j -го нейрона выходного слоя определяется, как

$$\gamma_j = y_j - t_j.$$

Для j -го нейронного элемента скрытого слоя:

$$\gamma_j = \sum_{i=1}^m \gamma_i y_i (1 - y_i) \omega_{ji},$$

где m – количество нейронных элементов следующего слоя по отношению к слою i .

Алгоритм обратного распространения ошибки. Как уже отмечалось, алгоритм обратного распространения ошибки был предложен в 1986 г. рядом авторов независимо друг от друга. Он является эффективным средством обучения нейронных сетей и представляет собой следующую последовательность шагов:

1. Задается шаг обучения α ($0 < \alpha < 1$) и желаемая среднеквадратичная ошибка нейронной сети E_m .
2. Случайным образом инициализируются весовые коэффициенты и пороговые значения нейронной сети.
3. Последовательно подаются образы из обучающей выборки на вход нейронной сети. При этом для каждого входного образа выполняются следующие действия:
 - а) производится фаза прямого распространения входного образа по нейронной сети. При этом вычисляется выходная активность всех нейронных элементов сети:

$$y_j = F\left(\sum_i \omega_{ij} y_i - T_j\right),$$

где индекс j характеризует нейроны следующего слоя по отношению к слою i .

- б) производится фаза обратного распространения сигнала, в результате которой определяется ошибка $\gamma_j, j = 1, 2, \dots$ нейронных элементов для всех слоев сети. При этом соответственно для выходного и скрытого слоев:

$$\gamma_j = y_j - t_j, \quad \gamma_j = \sum_i \gamma_i F'(S_i) \omega_{ji}.$$

В последнем выражении индекс i характеризует нейронные элементы следующего слоя по отношению к слою j .

- в) для каждого слоя нейронной сети происходит изменение весовых коэффициентов и порогов нейронных элементов:

$$\omega_{ij}(t+1) = \omega_{ij}(t) - \alpha \gamma_j F'(S_j) y_i,$$

$$T_j(t+1) = T_j(t) + \alpha \gamma_j F'(S_j).$$

4. Вычисляется суммарная среднеквадратичная ошибка нейронной сети:

$$E = \frac{1}{2} \sum_{k=1}^L \sum_j (y_j^k - t_j^k)^2,$$

где L – размерность обучающей выборки.

5. Если $E > E_m$ то происходит переход к шагу 3 алгоритма. В противном случае алгоритм обратного распространения ошибки заканчивается.

Таким образом, данный алгоритм функционирует до тех пор, пока суммарная среднеквадратичная ошибка сети не станет меньше заданной, т. е. $E \leq E_m$.

Опишем алгоритм функционирования ПИД-регулятора.

ПИД-регулятор в дискретном времени описывается следующим выражением

$$u_n = u_{n-1} + K_P(e_n - e_{n-1}) + K_I e_n + K_D(e_n - 2e_{n-1} + e_{n-2}),$$

где K_P, K_I и K_D – пропорциональный, интегральный и дифференциальный коэффициенты соответственно, u_n определяет вход объекта управления в момент $t = nT_0$ и e_n – ошибка между желаемым значением выхода r_n и реальным, то есть

$$e_n = r_n - y_n,$$

T_0 определяет единичный интервал времени.

Для настройки K_P, K_I и K_D во время работы мы будем использовать трехслойный перцептрон. Каждый слой состоит из N_1, N_2 и N_3 нейронов соответственно. Количество нейронов выбирается исходя из экспертного опыта и сложности объекта управления, N_3 равняется трем – количество коэффициентов ПИД. Для использования алгоритма обратного распространения ошибки мы должны выбрать функцию E , значение которой должно быть минимизировано. В качестве такой функции будет выступать ошибка управления e_n в момент времени nT_0 .

$$E_n = \frac{1}{2} e_n^2.$$

Для накопления ошибок сохраняем полученные ранее данные – $E_{n-p}, \dots, E_{n-2}, E_{n-1}, E_n$, где p определяет количество сохраненных ранее образов, используемых для обучения сети.

Компьютерное моделирование. Для компьютерного моделирования получим дискретную модель процесса пастеризации на основе формулы (1). Рассмотрим процесс без участия звена запаздывания e^{-pt_s} , положим $k = K_n$. Выберем достаточно малый шаг времени h и будем вычислять значения сигналов на выходе в дискретные равноотстоящие моменты времени $t = hl$ ($l = 0, 1, 2, \dots$). Выходную величину определим по рекуррентным формулам квадратичной интерполяции на основе значений сигнала, полученных в предыдущие моменты времени. Дифференциальное уравнение процесса в интервале $(l-1)h < t \leq hl$ имеет вид:




Рис. 9. Результаты моделирования процесса пастеризации

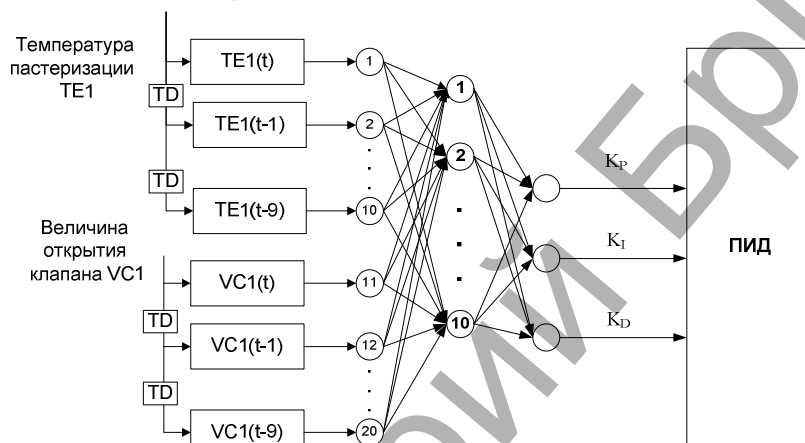


Рис. 10. Настройщик ПИД

$$Tdy(\tau) / d\tau + y(\tau) = kx(\tau),$$

где $\tau = t - (l-1)h$.

При $\tau = 0$ значения $x[(l-1)h] = x_{l-1}$, $y[(l-1)h] = y_{l-1}$.

Переходя к изображениям по Лапласу и решая уравнение относительно $Y(p)$, получим:

$$Y(p) = \frac{1}{1+pT} y_{l-1} + \frac{k}{1+pT} [X(p) - x_{l-1}].$$

При использовании квадратичной интерполяции сигнал $x(t)$ в интервале $[(l-1)h, lh]$ определяется значениями x для трех моментов времени $x_l = x(lh)$, $x_{l-1} = x[(l-1)h]$ и $x_{l-2} = x[(l-2)h]$, т.е.:

$$x(t) = x_{l-1} + \frac{x_l - x_{l-2}}{2h} + \frac{x_l - 2x_{l-1} + x_{l-2}}{h^2}$$

или в изображениях:

$$x(p) = \frac{x_{l-1}}{p} + \frac{x_l - x_{l-2}}{2h} \cdot \frac{1}{p^2} + \frac{x_l - 2x_{l-1} + x_{l-2}}{h^2} \cdot \frac{1}{p^3}.$$

Выполняя подстановку и обратное преобразование Лапласа, при $\tau = h$, т.е. в конце интервала ($t = lh$), имеем:

$$y_l = \gamma y_{l-1} + Ax_l + Bx_{l-1} + Cx_{l-2},$$

где

$$\left. \begin{aligned} \gamma &= e^{-h/T}; \\ A &= \frac{k}{2h^2} [(1-\gamma)(2T^2 - Th) + 2h^2 - 2Th]; \\ B &= -\frac{k}{h^2} [(1-\gamma)(2T^2 - h^2) + h^2 - 2Th]; \\ C &= \frac{k}{2h^2} [(1-\gamma)(2T^2 + Th) - 2Th]. \end{aligned} \right\}$$

С учетом запаздывания τ_s получим [3]:

$$y_l = \gamma y_{l-1} + Ax_{l-\tau_s} + Bx_{l-\tau_s-1} + Cx_{l-\tau_s-2}.$$

Рис. 9 показывает результаты моделирования для следующих значений параметров $k = 525$ и $T = 450$ (см. табл. 1), $K_p = 0,5$, $K_i = 5$ и $K_d = 0,01$, требуемое задание 90°C .

В качестве настройщика ПИД использовался многослойный персептрон (MLP) со следующей структурой: 20 входных, 10 скрытых и 3 выходных нейронных элемента; функция активации скрытого и выходного слоев – сигмоидная (рис. 10).

Для предварительного обучения использовались сохраненные данные работы объекта управления – 50 первых точек, размер окна – 10, точность обучения 0.00005 (рис. 9). Если во время работы в течение 10-ти тактов времени ошибка управления превышала 2, то происходило обучение нейронной сети, точность обучения 0.0001, ограничение на количество итераций обучения – 10.

Результаты моделирования показывает рис. 11 и 12.

Видно, что при изменении задания переходной процесс не изменяется и сохраняется один и тот же уровень перерегулирования, так как коэффициенты ПИД-регулятора статичны. Значение перерегулирования $\delta = 5^\circ\text{C}$ (5%).

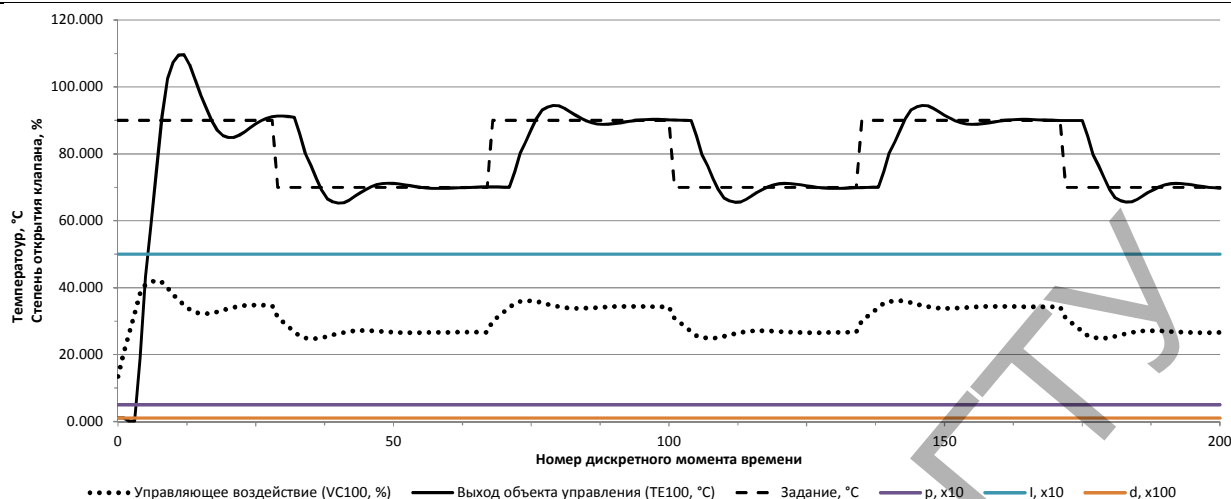


Рис. 11. Результаты моделирования. Работа обычного ПИД-регулятора

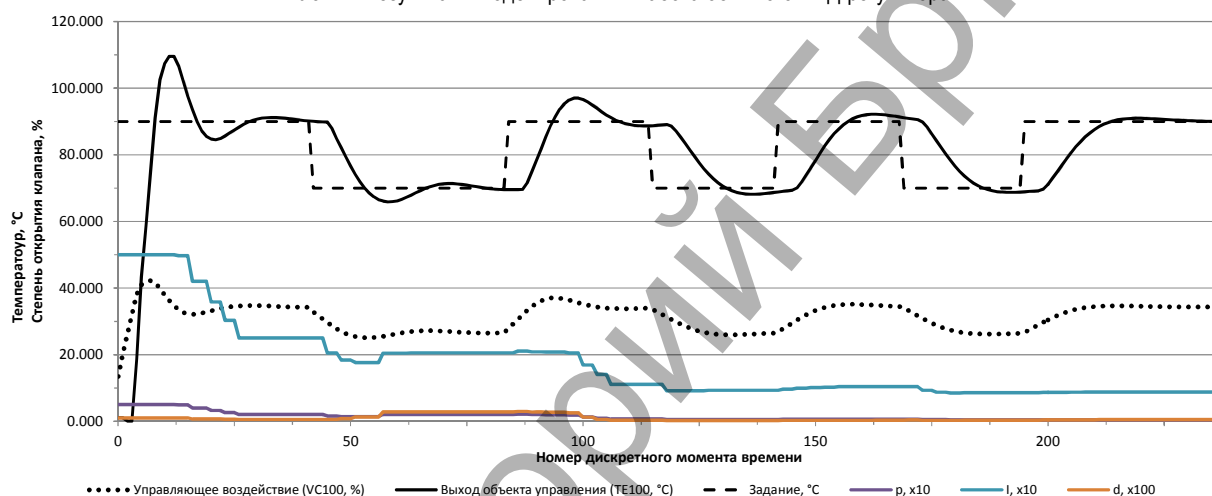


Рис. 12. Результаты моделирования. Работа нейро-ПИД-регулятора

Можно убедиться, что при четвертом и пятом изменении задания переходной процесс улучшается. Начальные значения коэффициентов $K_P = 0,5$, $K_I = 5$ и $K_D = 0,01$, после надстройки – $K_P = 0,43$, $K_I = 0,9$ и $K_D = 0,005$, значение перерегулирования $\delta = 1^\circ\text{C}$ (1%).

Заключение. Задача повышения качества управления процессом пастеризации является актуальной в настоящее время. Использование нейро-ПИД регулятора предложено как альтернатива другим самонастраивающимся схемам ПИД. Была разработана структура и алгоритм работы нейро-ПИД регулятора пастеризационной установки. Тестирование показало эффективность данной схемы.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Тетра, Пак Технология производства молочных продуктов: справочник. – Tetra Pak Processing Systems AB, 1995.
2. Брусиловский, Л.П. Автоматизация технологических процессов в молочной промышленности / Л.П. Брусиловский, А.Я. Вайнберг – М.: Пищевая промышленность, 1978.

3. Нетушил, А.В. Теория автоматического управления: учебник для вузов. – Изд. 2-е, доп. и перераб. – М.: Высшая школа, 1976.
4. White, D.A. Ed.: Handbook of Intelligent Control. Neural, Fuzzy, and Adaptive Approaches / D.A. White, D.A. Sofge. – Van Nostrand Reinhold, 1992.
5. Sigeru, Omatu Neuro-Control And Its Applications / Omatu Sigeru, B. Khalid Marzuki, 1996.
6. Sigeru Omatu, Michifumi Yoshioka: Self-Tuning Neuro-PID Control and Applications, Department of Computer and Systems Sciences, College of Engineering, Osaka Prefecture University, Sakai, Osaka, Japan.
7. Michiyo Suzuki, Toru Yamamoto, Kazuo Kawada, Hiroyuki Sogo: A Design of Neural-Net Based Self-Tuning PID Controllers, Lecture Notes in Computer Science Volume 2130, 2001.
8. Azadeh Mansouri Mansourabad, Mohammad Taghi Hamidi Beheshti, Mohsen Simab: A Hybrid PSO_Fuzzy_PID Controller for Gas Turbine Speed, International Journal of Control and Automation. – Vol. 6. – No. 1. – February, 2013.
9. Головкин, В.А.: Нейроинтеллект: теория и применение. – Книга 1: организация и обучение нейронных сетей с прямыми и обратными связями. – Брест: БПИ, 1999.

Материал поступил в редакцию 12.01.15

IVANYUK D.S. POU neuro-PID-regulator

The neuro-PID controller for the pasteurizer was developed. It consists of two parts: the conventional PID (proportional plus integral plus derivative controller) and the neural network, which is based on the multilayer perceptron structure. The outputs of the neural network are proportional (P), integral (I), and derivative (D) gains. The simulation and experimental results show the effectiveness of the proposed approach.