

**Бобырь Максим Владимирович** – Юго-Западный государственный университет; e-mail: max\_b@mail333.com, fregat\_mn@rambler.ru; 305040, г. Курск, ул. 50 лет Октября, 94; тел.: 84712587105, 89202643455; кафедра вычислительной техники; д.т.н.; доцент; профессор кафедры.

**Титов Виталий Семенович** – e-mail: titov-kstu@rambler.ru; тел.: 84712587112; кафедра вычислительной техники; зав. кафедрой; д.т.н.; профессор; заслуженный деятель науки РФ; академик Международной академии наук высшей школы.

**Bobyry Maxim Vladimirovich** – South-West State University; e-mail: fregat\_mn@rambler.ru, max\_b@mail333.com; 94, 50 years of October street, Kursk, 305040, Russia; phone: +74712587105, +79202643455; the department of computer science; dr. of eng. sc.; associate professor; professor of department.

**Titov Vitaly Semenovich** – e-mail: titov-kstu@rambler.ru; phone: +74712587112; the department of computer science; head of department; dr. of eng. sc.; professor.

УДК 004.89 + 681.51

**Ю.И. Еременко, Д.А. Полещенко, А.И. Глущенко**

**О РАЗРАБОТКЕ МЕТОДА ОПРЕДЕЛЕНИЯ ЗНАЧЕНИЙ ЗАДЕРЖЕК  
ВХОДНЫХ СИГНАЛОВ НЕЙРОННОЙ СЕТИ ПРИ РЕАЛИЗАЦИИ  
НЕЙРОСЕТЕВОГО ОПТИМИЗАТОРА ПАРАМЕТРОВ ПИ-РЕГУЛЯТОРА\***

*Нейросетевой оптимизатор позволяет осуществлять в реальном масштабе времени подстройку параметров  $K_p$  и  $K_I$  ПИ-регулятора для повышения энергоэффективности несимметричных объектов управления, описываемых апериодическими звеньями первого и второго порядков с запаздыванием. Основной составляющей оптимизатора является нейронная сеть, в вектор входных параметров которой входят задержанные на равные промежутки времени  $\Delta t$  друг от друга сигналы с выхода объекта управления. Целью исследования являлась разработка метода для вычисления значения  $\Delta t$  в зависимости от значений параметров регулируемого процесса. Было проведено более 15 000 вычислительных экспериментов с моделями объектов управления с различными значениями постоянных времени, коэффициента усиления и времени запаздывания. Для каждой конкретной модели применялись значения  $\Delta t$  в диапазоне от 1 до 40 с. В наборе из 40 опытов выбирался лучший по предложенному критерию, что и определяло оптимальное значение  $\Delta t$  для рассматриваемой модели. По результатам экспериментов была аппроксимирована искомая аналитическая зависимость. Также было показано, что количество  $N$  обращений к нейросетевому оптимизатору в течение конкретного переходного процесса в целом является постоянной величиной для всех опытов, при условии, что вызов оптимизатора осуществляется раз в  $\Delta t$  секунд. Было показано, что кривая распределения значений величины  $N$  подчиняется нормальному распределению. Для данных фактов приведено теоретическое обоснование и, благодаря этому, предложен подход к вычислению  $\Delta t$  без необходимости знания значений параметров объекта управления. В дальнейшем предполагается включить параметр  $\Delta t$  в алгоритм обучения нейросетевого оптимизатора для его оперативной коррекции в процессе работы, а полученную аналитическую зависимость использовать для вычисления начального значения  $\Delta t$ .*

*Адаптивное управление; нейронные сети; ПИ-регулятор; нейросетевой оптимизатор; время задержки входных сигналов.*

\* Работа выполнена при поддержке РФФИ (гранты 13-08-00532-а, 15-07-0609215) и фонда Президента РФ (грант №14.У30.15.4865-МК).

Y.I. Eremenko, D.A. Poleshchenko, A.I. Glushchenko

**ON DEVELOPMENT OF METHOD TO CALCULATE TIME DELAY VALUES  
OF NEURAL NETWORK INPUT SIGNALS TO IMPLEMENT  
PI-CONTROLLER NEURAL TUNER**

*A neural tuner is used to increase energy efficiency of unsymmetrical plants described by first or second order aperiodic links with time delay. It allows to tune KP and KI parameters of a PI-controller online without knowledge of plants model. A main part of the tuner is a neural network, which input vector includes plant output value signals delayed on equal time gaps  $\Delta t$  from each other. The main aim of the research is to develop a method to calculate  $\Delta t$  depended on plant parameters values. More than 15000 experiments are conducted with plant models using different values of time constant, plant gain and delay time.  $\Delta t$  values are changed from 1 s to 40 s for each certain model. The best experiment is chosen from the set of 40 on the basis of proposed criteria. Such experiment shows the best value of  $\Delta t$  for the plant model in question. Having conducted experiments, sought analytical dependence is found. It is also shown that the number of the neural tuner calls  $N$  during each transient of each experiment with the best value of  $\Delta t$  is a constant. The neural tuner is called every  $\Delta t$  seconds. It is also shown that  $N$  value probability curve is Gaussian distribution. Such facts are proved theoretically. On that base a method to calculate  $\Delta t$  value without knowledge about plant parameters values is proposed. Further research needs to be done to include parameter  $\Delta t$  into neural network operative training process to be able to refine it during control system functioning. In that case obtained analytical dependence will be used to initialize  $\Delta t$ .*

*Adaptive control; neural networks; PI-controller; neural tuner; input signals time delay.*

**Введение.** В настоящее время порядка 90 % регуляторов, находящихся в промышленной эксплуатации, используют ПИ- или ПИД-алгоритм управления [1, 2]. Такие регуляторы являются линейными, в то время как реальные объекты управления (ОУ) в большинстве случаев нелинейны. Подобное несоответствие приводит к тому, что коэффициенты регулятора, подобранные при первичной настройке для конкретного режима работы объекта, не позволяют получать сходных по качеству переходных процессов в других режимах (например, при загрузке нагревательной печи). Это ведет к увеличению времени на отслеживание уставок и, соответственно, расхода энергоносителя.

Одним из возможных решений данной проблемы является построение адаптивных систем управления технологическими процессами [1, 2], автоматически подбирающих коэффициенты ПИ или ПИД-регуляторов. Всю совокупность методов построения таких систем можно разбить на две группы. Первая группа – это классические методы [3–7]. Большинство таких методов основано на использовании значений параметров модели ОУ, идентифицированной с помощью тестовых сигналов (ступенчатых или полигармонических). При этом в условиях производства идентификация объекта является весьма нетривиальной задачей.

Вторая группа – это методы, основанные на методологии искусственного интеллекта, например, подходы, предложенные в [8–15], и, в частности, нейронные сети (НС) [8, 9, 11, 12, 13, 15]. Они обладают способностью к обучению, однако не для всех объектов возможно получить автономную обучающую выборку, а кроме того, нейронные сети не обладают сведениями о специфике того ОУ, которым управляют (ограничения на сигнал управления, невозможность принудительного охлаждения печей и т.д.). В свою очередь, нечеткая логика и экспертные системы [10, 14] позволяют учитывать подобную специфику, но не могут быть обучены в оперативном режиме.

Для решения указанной проблемы авторами данной работы предложен метод построения нейросетевого оптимизатора параметров ПИ-регулятора [16], объединяющий НС для коррекции коэффициентов регулятора с базой правил ситуаций, когда необходимо проводить настройку. Данный метод предназначен для управ-

ления процессами, относящимися, в соответствии с [17], к классу несимметричных. Важной задачей при построении нейросетевого оптимизатора является определение параметров НС. В частности, полученная по результатам исследований [18] структура НС имеет пять входов, три из которых являются задержанными на равные интервалы  $\Delta t$  секунд друг от друга выходными сигналами ОУ. Целью данного исследования является разработка метода вычисления значения  $\Delta t$  с использованием модели ОУ и без нее.

**1. Постановка задачи.** Объектом исследований является система управления, представленная на рис. 1. ОУ описывается двумя аperiodическими звеньями первого порядка со звеном задержки (1). Первое из них является моделью самого объекта, а второе – моделью прибора для измерения контролируемого в ОУ параметра.



Рис. 1. Система управления с настройкой параметров регулятора

$$W(s) = \frac{K}{T_1 s + 1} \cdot \frac{1}{T_2 s + 1} \cdot e^{-\tau \cdot s}, \quad (1)$$

где  $K$  – коэффициент усиления ОУ;  $T_1$  – постоянная времени ОУ, с;  $T_2$  – постоянная времени измерительного прибора, с;  $\tau$  – время запаздывания, с.

Задачей контура управления, изображенного на рис. 1, является отслеживание графика уставок, представляющего собой набор ступенчатых изменений задания, таким образом, чтобы, с одной стороны, переходные процессы протекали за минимальное количество времени. Это позволит интенсифицировать производство и сократить потери энергоносителя. С другой стороны, качество получаемых переходных процессов по перерегулированию, колебательности и статической ошибке должно находиться в пределах допуска.

В данном случае предполагается, что ОУ уже функционирует под управлением ПИ-регулятора и его коэффициенты изначально подобраны для одного из состояний объекта. Задачей является подстройка (а не полное переопределение) коэффициентов ПИ-регулятора в соответствии с изменениями режима работы ОУ для поддержания времени переходных процессов для всех режимов близким к минимальному.

Для этого предлагается применить нейросетевой оптимизатор параметров ПИ-регулятора. Он не предполагает построение модели ОУ. Вместо этого производится оценка ситуации на ОУ (в частности, текущей скорости переходного процесса) с помощью базы правил с дальнейшими выводами о необходимости обучения НС.

Основной составляющей оптимизатора является нейронная сеть. Количество и вид входов НС были определены экспериментальным путем в ходе исследований, результаты которых совпали с [11]. Во входном слое расположено 5 нейро-

нов: текущее задание ( $x_1$ ); задержанный на 1 секунду ( $x_2$ ), на  $\Delta t$  секунд ( $x_3$ ) и на  $2 \cdot \Delta t$  секунд ( $x_4$ ) сигнал по выходу ОУ; задержанный на 1 секунду сигнал управления, формируемый ПИ-регулятором ( $x_5$ ). Входные сигналы нормируются в интервал  $[0;1]$ . Обращение к НС также происходит раз в  $\Delta t$  секунд. Целью данной статьи является определение оптимального значения  $\Delta t$  в зависимости от параметров ОУ.

**2. Описание нейросетевого оптимизатора.** Многие реальные технологические процессы являются несимметричными, т.е. включают в себя два режима с различной динамикой. Например, нагревательные печи работают в режимах нагрева и охлаждения. В [17] было выявлено, что для оптимальности ведения и того, и другого процесса требуется два набора коэффициентов регулятора, а не один. В связи с этим предлагается реализовывать нейросетевой оптимизатор в виде двух идентичных нейронных сетей, каждая из которых отвечает за управление коэффициентами регулятора для своего типа процесса. Поэтому первоначально создаются две необученные НС. Они имеют одинаковую трехслойную структуру, так как в соответствии с [19] любая непрерывная функция может быть аппроксимирована с необходимой точностью трехслойной НС. Структура входного слоя была представлена выше. Проведенные исследования [18] показали, что 15 нейронов в скрытом слое являются оптимальным числом. В скрытом слое была использована сигмоидальная функция активации, в выходном слое – линейная функция. В выходном слое используется два нейрона (отвечают за  $K_p$ ,  $K_I$ ).

Обе сети начинают работу с формирования на своем выходе одинаковых значений  $K_p$  и  $K_I$ , используемых на ОУ в текущий момент. Для этого использован метод экстремального обучения [20].

Далее обе НС нейросетевого оптимизатора предлагается оперативно обучать с помощью алгоритма обратного распространения ошибки [11]. Общей целью обучения является минимизация рассогласования между выходом ОУ и заданием. В отличие от [11], в данной работе предлагается значения скорости обучения  $\eta_j$  для нейронов выходного слоя НС сделать различными и изменять их в течение работы системы.  $\eta_1$  – это скорость коррекции весовых коэффициентов и смещения, отвечающих за формирование первого выхода НС, т.е.  $K_p$ . Соответственно  $\eta_2$  отвечает за  $K_I$ . Необходимость такого подхода вызвана, во-первых, тем фактом, что порядок значений коэффициентов регулятора обычно различается (например,  $K_p = 2 \cdot 10^{-1}$ , а  $K_I = 1,5 \cdot 10^{-4}$ ). Во-вторых, нет необходимости изменять коэффициенты регулятора постоянно, а в некоторые моменты коррекции требует только один из них. Поэтому в начале каждой итерации работы нейросетевого оптимизатора обе указанные скорости приравниваются к нулю, а затем происходит вызов предлагаемой базы правил [16]. Условия правил описывают ситуации, когда необходимо использовать и обучать НС, а следствия – необходимые значения  $\eta_1$ ,  $\eta_2$ . Если какое-либо из правил срабатывает, то происходит обучение НС.

**3. Реализация системы управления с нейросетевым оптимизатором и описание эксперимента для определения  $\Delta t$ .** В пакете Matlab была реализована система управления моделью ОУ (рис. 2), описываемой (1). Контур управления представлен блоком *Subsystem* с ПИ-регулятором с нейросетевым оптимизатором (*S-function neuC\_PI*).  $U_i$ ,  $U_p$ ,  $U_{pi}$  – сигналы управления на выходе  $i$ -,  $p$ -каналов и всего ПИ-регулятора соответственно,  $e$  – текущее рассогласование. Блок *Saturation* использован для ограничения получаемого с ПИ-регулятора сигнала управления до диапазона  $[0;100]$  для придания ОУ несимметричных свойств.  $U$  – управляющее воздействие, подаваемое на ОУ.

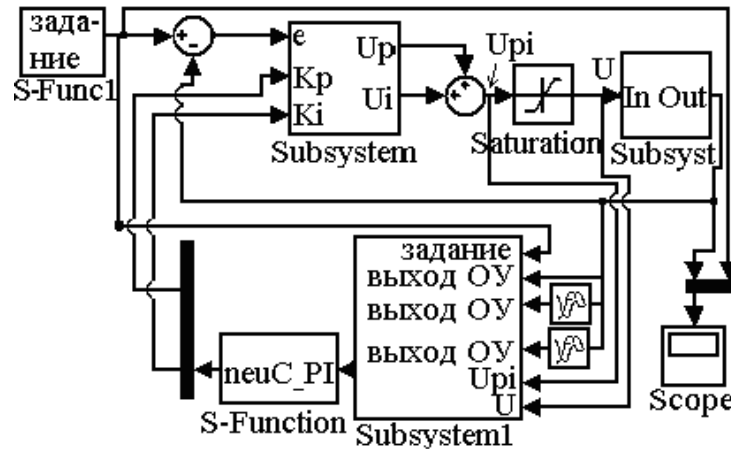


Рис. 2. Система управления с нейросетевым оптимизатором

Для каждого опыта было использовано по два набора параметров модели (сочетания), между которыми осуществлялось подобное переключение: первое состояние – 12 переходов с параметрами  $(T_1, \tau)$  → второе состояние – 12 переходов с параметрами  $(2 \cdot T_1, 2 \cdot \tau)$  → первое состояние – 12 переходов с параметрами  $(T_1, \tau)$ . Значение  $T_2$  всегда составляло 5 % от  $T_1$ . Начальные значения коэффициентов ПИ-регулятора для каждого сочетания были подобраны для первого состояния ОУ. Задачей оптимизатора было сначала подобрать новые коэффициенты для измененного состояния объекта, а затем вернуть исходные параметры при возврате к исходному состоянию ОУ. Для смены уставки выход ОУ должен был удерживаться в 5 % окрестности значения разности текущего задания и предшествующего в течение 1800 секунд. Для каждого из сочетаний параметров ОУ также был проведен опыт с системой управления с ПИ-регулятором, который использовал значения коэффициентов, подобранные для первого состояния ОУ, в течение всего эксперимента.

Всего было проведено 17 280 экспериментов: для каждого из трех значений коэффициента усиления ОУ  $K = 10, 20$  и  $30$  было использовано по 144 различных сочетания значений остальных параметров модели ОУ ( $T_1 \in [10 \text{ с}; 15000 \text{ с}]$ ,  $\tau \in [1 \text{ с}; 450 \text{ с}]$ ). Для каждого такого сочетания было проведено по 40 опытов со значениями  $\Delta t$  от 1 секунды до 40 секунд. В каждом таком наборе из 40 опытов выбирался лучший. Для этого был разработан критерий оптимальности в виде суммы следующих значений, нормированных в промежуток  $[0;1]$  относительно текущего набора из 40 опытов: время текущего опыта, среднее перерегулирование за весь опыт и сумма квадратов отклонений выхода ОУ от задания за все время опыта. Выбирался опыт с минимальным значением критерия среди имеющихся. При этом использовались следующие ограничения: завершены все 36 переходных процессов, среднее перерегулирование за все время опыта не могло быть более 5 % от разницы предшествующего и текущего заданий, а общее время опыта должно было быть меньше, чем время, показанное системой с обычным ПИ-регулятором в таких же условиях для такой же модели ОУ. Значение  $\Delta t$  для данного опыта выбиралось как лучшее для данного сочетания параметров ОУ.

В дальнейшем апробация разработанного метода определения  $\Delta t$  произведена на примере муфельных печей, поэтому для моделирования (для всех моделей ОУ) был выбран следующий график изменения заданий:  $590^\circ\text{C} \rightarrow 640^\circ\text{C} \rightarrow 505^\circ\text{C} \rightarrow 590^\circ\text{C}$ , являющийся уменьшенной в два раза по амплитуде копией графика для печи нагрева литой заготовки перед прокатом.

**4. Результаты экспериментов.** По итогам моделирования для каждого конкретного набора параметров модели ОУ было определено оптимальное значение параметра  $\Delta t$ . Полученные результаты представлены в виде поверхности для  $K = 10$ , отражающей зависимость оптимального значения  $\Delta t$  от  $T_1$  и  $\tau$  (рис. 3). Поверхности для  $K = 20$  и  $K = 30$  имеют сходный вид. Кроме того, по полученным данным аппроксимирован аналитический вид зависимости (2)  $\Delta t$  от  $K$ ,  $T_1$  и  $\tau$ .




Рис. 3. Зависимость  $\Delta t$  от  $T_1$  и  $\tau$  при  $K=10$

$$\begin{aligned}
 \Delta t = & 4,5 - 4,5 \cdot 10^{-12} K^8 + 1,91 \cdot 10^{-23} K^3 T_1^3 \tau^3 + 1,32 \cdot 10^{-15} K^3 T_1^3 - 5,29 \cdot 10^{-12} K^3 T_1^2 + \\
 & + 1,44 \cdot 10^{-8} K^3 T_1 + 1,27 \cdot 10^{-11} K^3 \tau^3 - 8,03 \cdot 10^{-9} K^3 \tau^2 + 3,38 \cdot 10^{-6} K^3 \tau - \\
 & - 5,39 \cdot 10^{-15} K^2 T_1^2 \tau^2 - 3,84 \cdot 10^{-10} K^2 T_1^2 + 1,06 \cdot 10^{-5} T_1^2 / K^2 - 0,12 \cdot T_1 / K^2 - \\
 & - 1,78 \cdot 10^{-7} K^2 \tau^2 - 0,02 \tau^2 / K^2 + 10,45 \tau / K^2 - 320,6 / K^2 - 2,25 \cdot 10^{-6} T_1^2 / K + \\
 & + 2,92 \cdot 10^{-7} K T_1 \tau - 1,39 \cdot 10^{-4} T_1 \tau / K + 2,7 \cdot 10^{-2} T_1 / K - 1,26 \cdot 10^{-3} \tau^2 / K + 0,46 \tau / K + \\
 & + 18,28 / K + 1,84 \cdot 10^{-31} T_1^8 - 8,99 \cdot 10^{-12} T_1^2 \tau^2 + 1,56 \cdot 10^{-9} T_1^2 \tau - 3,49 \cdot 10^{-7} T_1^2 + \\
 & + 1,27 \cdot 10^{-7} T_1 \tau^2 - 1,43 \cdot 10^{-5} T_1 \tau + 4,1 \cdot 10^{-3} T_1 - 1,15 \cdot 10^{-20} \tau^8 - 6,57 \cdot 10^{-5} \tau^2 + 2,28 \cdot 10^{-3} \tau.
 \end{aligned} \quad (2)$$

Для моделей ОУ, в которых  $\tau > 0,1 T_1$ , ни одно из значений  $\Delta t$  не удовлетворяло предъявленным требованиям. Таким образом, для применения нейросетевого оптимизатора необходимо, чтобы  $\tau \leq 0,1 T_1$ .

Однако зависимости (2) может оказаться недостаточно для вычисления значения  $\Delta t$  при условии того, что в случае внедрения оптимизатора на реальный ОУ, модель такого ОУ будет неизвестна. Поэтому также необходим метод оценки  $\Delta t$  без модели ОУ. При решении данной задачи для каждой из моделей ОУ, используя выбранное оптимальное значение  $\Delta t$ , оценивалось усредненное по всем переходным процессам значение времени  $T_{III}$ , в течение которого рассогласование между выходом ОУ и заданием находилось в пределах от 10 до 80 % разницы между текущим заданием и предыдущим. Этот промежуток времени важен с точки зрения правил, определяющих моменты обучения нейронной сети. Если НС не будет вызвана в течение этого промежутка времени, то нейросетевой оптимизатор не сможет настроить коэффициенты регулятора, а вызывается такая сеть раз в  $\Delta t$  секунд. Имея значение  $T_{III}$  и разделив его на значение  $\Delta t$  для текущей модели ОУ, можно получить сколько в среднем раз за время переходного процесса был вызван нейросетевой оптимизатор:  $N = T_{III} / \Delta t$ .

Вычислив значение  $N$  для всех опытов, для которых удалось определить оптимальное значение  $\Delta t$ , было замечено, что диапазон значений  $N$  составляет [9, 24]. Было решено провести статистический анализ данных результатов. В итоге было получено распределение, приведенное на рис. 4.



Рис. 4. Распределение появления значений  $N$

Согласно критерию Пирсона данное распределение является нормальным. Математическое ожидание (МО) величины  $N$  составляет 15,94. СКО – 3,48. Это дает основание полагать, что для всех сходных экспериментов значение  $N$  будет подчиняться данному распределению. Таким образом, при внедрении нейросетевого оптимизатора на работающий ОУ необходимо взять текущую картину заданий, выбрать самый короткий по времени переходный процесс при текущих настройках регулятора, разделить его длительность на 16 и получить требуемое значение  $\Delta t$ . Для такого подхода не требуется знание параметров модели ОУ.

Полученное значение математического ожидания величины  $N$  может быть обосновано с помощью результатов, приведенных в [19]. Согласно указанному исследованию, НС может запомнить и обобщить с практически нулевой ошибкой число примеров, совпадающее с числом нейронов в скрытом слое. В данном случае нейросетевой оптимизатор обучается в течение конкретного переходного процесса путем предъявления ему значений контролируемого параметра ОУ, снимаемого раз в  $\Delta t$  секунд. Соответственно, предъявляемые НС точки текущего переходного процесса – это и есть ее оперативная обучающая выборка. В соответствии с [19], чтобы НС была в состоянии их обобщить и подобрать новые значения параметров ПИ-регулятора, предъявляемых НС точек должно быть столько, сколько нейронов в ее скрытом слое, т.е. 15, что практически совпадает с МО величины  $N$ .

**5. Апробация метода вычисления  $\Delta t$  на лабораторных печах.** Эксперименты, подобные описанным в п. 3, были проведены на двух муфельных электронагревательных печах SNOL-1,6,2,5.1/11-И4 и SNOL 40/1200. Для каждой печи было выполнено по два опыта – для системы с нейросетевым оптимизатором и для обычного ПИ-регулятора.

Эксперимент заключался в следующем: с начального момента и до момента, когда задание было изменено 12 раз, муфельная печь была пустой, далее в нее загружалась литая заготовка объемом примерно 30 % от рабочего пространства печи и задание изменялось еще 12 раз, а затем печь разгружалась и проводилось еще 12 переходных процессов.

Для обеих печей в соответствии с подходами, предложенными в п. 4, было рассчитано значение  $\Delta t$ . Для SNOL-1,6,2,5.1/11-И4  $\Delta t = 20$  с, для SNOL 40/1200  $\Delta t = 10$  с. Результаты расчетов по методам с использованием модели ОУ и длительности переходных процессов для конкретной печи совпали. Результаты экспериментов для печи SNOL-1,6,2,5.1/11-И4 приведены на рис. 5, 6.




Рис. 5. Результаты системы управления с обычным ПИ-регулятором: 1 – момент загрузки печи; 2 – момент разгрузки печи

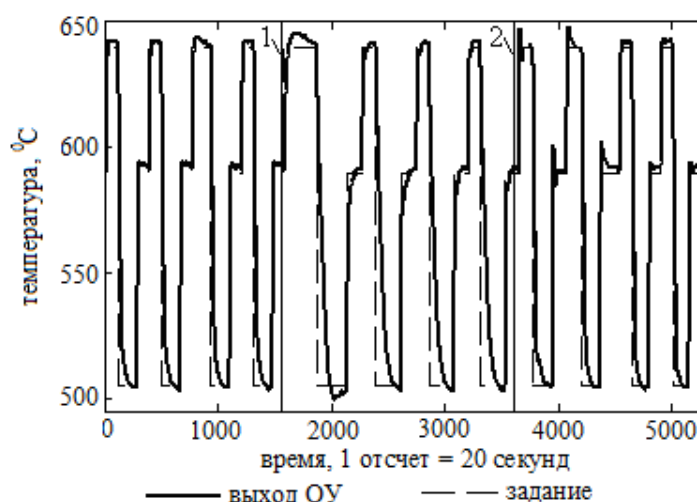


Рис. 6. Результаты применения нейросетевого оптимизатора: 1 – момент загрузки печи; 2 – момент разгрузки печи

В период работы загруженной печи система с нейросетевым оптимизатором позволила добиться 4 % перерегулирования для процессов нагрева и 2,2 % – для охлаждений, в то время как те же показатели для обычного ПИ-регулятора – 12 % и 4,5 % соответственно. Время опыта для системы с нейросетевым оптимизатором составило 29,08 часа при расходе электроэнергии 15,11 кВт\*ч, а для обычного ПИ-регулятора – 37,7 часа при расходе 17,56 кВт\*ч. Экономия по времени на выполнение графика задания при использовании оптимизатора составила 23 %, а электроэнергии – 14 %.

Результаты экспериментов для печи SNOL 40/1200 приведены на рис. 7, 8.






Рис. 7. Результаты системы управления с обычным ПИ-регулятором:  
1 – момент загрузки печи; 2 – момент разгрузки печи




Рис. 8. Результаты применения нейросетевого оптимизатора: 1 – момент загрузки печи; 2 – момент разгрузки печи

В период работы загруженной печи система с нейросетевым оптимизатором позволила добиться 4% перерегулирования для процессов нагрева, в то время как для обычного ПИ-регулятора этот показатель составил 9%. Время опыта для системы с нейросетевым оптимизатором составило 35,42 часа при расходе электроэнергии 17,24 кВт\*ч, а для обычного ПИ-регулятора – 36,87 часа при расходе 18,37 кВт\*ч. Экономия по времени на выполнение графика задания при использовании нейросетевого оптимизатора составила 4%, а электроэнергии – 6%. Полученные результаты подтверждают адекватность предложенного метода определения значения  $\Delta t$ .

**Заключение.** Предложенный метод расчета значений задержек входных сигналов НС нейросетевого оптимизатора параметров ПИ-регулятора  $\Delta t$  может быть применен для уже функционирующих под управлением ПИ-регулятора объектов управления, которые можно описать двумя апериодическими звеньями первого порядка с запаздыванием. При этом модель ОУ может быть неизвестна. Проведенные эксперименты показали адекватность разработанного подхода. В дальнейшем предполагается включить параметр  $\Delta t$  в алгоритм обучения нейросетевого оптимизатора для его оперативной коррекции в процессе работы, а полученную аналитическую зависимость использовать для вычисления начального значения  $\Delta t$ .

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Astrom K.J., Hagglund T., Hang C.C., Ho W.K.* Automatic tuning and adaptation for PID controllers. A survey // IFAC J. Control Eng. Practice. – 1993. – Vol. 1, No. 4. – P. 699-714.
2. *Astrom K.J., Hagglund T.* Advanced PID Control. – Research Triangle Park: ISA – The Instrumentation, Systems, and Automation Society, 2006. – 461 p.
3. *Alexandrov A.G., Palenov M.V.* Self-tuning PID-I controller: Proceedings of the 18th IFAC World Congress. Mi-lano, Italy, 2011. – P. 3635-3640.
4. *Pfeiffer B.-M.* Towards «plug and control»: self-tuning temperature controller for PLC // International journal of Adaptive Control and Signal Processing. – 2000. – No. 14. – P. 519-532.
5. *Ziegler J., Nichols N.* Optimum settings for automatic controllers // Trans. ASME. – 1942. – No. 65. – P. 759-768.
6. *Шубладзе А.М., Кузнецов С.И.* Автоматически настраивающиеся промышленные ПИ- и ПИД-регуляторы // Автоматизация в промышленности. – 2007. – № 2. – С. 15-17.
7. *Ротач В.Я., Кузицин В.Ф., Петров С.В.* Настройка регуляторов по переходным характеристикам систем управления без их аппроксимации аналитическими выражениями // Автоматизация в промышленности. – № 11. – 2009. – С. 9-12.
8. *Chen J., Huang T.* Applying neural networks to on-line updated PID controllers for nonlinear process control // Journal of Process Control. – 2004. – № 14. – P. 211-230.
9. *Fang M., Zhuo Y., Lee Z.* The application of the self-tuning neural network PID controller on the ship roll reduction in random waves // Ocean Engineering. – 2010. – № 37. – P. 529-538.
10. *Anderson K.L., Blankenship G.I., Lebow L.G.* A rule-based adaptive PID controller // Proc. 27th IEEE Conf. Decision. Control, 1988. – P. 564-569.
11. *Omatu S., Khalid M., Yusof R.* Neuro-Control and its Applications. – London: Springer, 1995. – 255 p.
12. *Reyes J., Astorga C., Adam M., Guerrero G.* Bounded neuro-control position regulation for a geared DC motor // Engineering Applications of Artificial Intelligence. – 2010. – No. 23. – P. 1398-1407.
13. *Tan S.-H., Hang C.-C., Chai J.-S.* Gain scheduling: from conventional to neuro-fuzzy // Automatica. – 1997. – Vol. 33, No. 3. – P. 411-419.
14. *Zhao Z.Y., Tomizuka M., Isaka S.* Fuzzy gain scheduling of PID controllers // IEEE Transactions on systems, man, and cybernetics. – 1993. – No. 5. – P. 1392-1398.
15. *Unal M., Ak A., Topuz V., Erdal H.* Optimization of PID Controllers Using Ant Colony and Genetic Algorithms. – London: Springer, 2013. – 85 p.
16. *Еременко Ю.И., Полеценко Д.А., Глуценко А.И.* О применении нейросетевого оптимизатора параметров ПИ-регулятора для управления нагревательными печами в различных режимах работы // Управление большими системами. – 2015. – Вып. 56. – С.143-175.
17. *Hagglund T., Tengvall A.* An automatic tuning procedure for unsymmetrical processes // Proceedings of 3rd European control conference, 1995. – P. 2450-2455.
18. *Еременко Ю.И., Полеценко Д.А., Глуценко А.И., Фомин А.В.* Об оценке применимости различных структур нейронной сети в реализации нейросетевого оптимизатора параметров ПИ-регулятора для управления тепловыми объектами // Системы управления и информационные технологии. – 2014. – № 3.2 (57). – С. 236-241.
19. *Hornik K., Stinchcombe M., White H.* Multilayer feed-forward networks are universal approximators // Neural networks. – 1989. – No. 2 (5). – P. 359-366.
20. *Huang G.B., Wang D.H., Lan Y.* Extreme learning machines: a survey // International Journal of Machine Learning Cybernetics. – 2011. – No. 2. – P. 107-122.

## REFERENCES

1. *Astrom K.J., Hagglund T., Hang C.C., Ho W.K.* Automatic tuning and adaptation for PID controllers. A survey, *IFAC J. Control Eng. Practice*, 1993. – Vol. 1, No. 4. – P. 699-714.
2. *Astrom K.J., Hagglund T.* Advanced PID Control. Research Triangle Park: ISA – The Instrumentation, Systems, and Automation Society, 2006, 461 p.
3. *Alexandrov A.G., Palenov M.V.* Self-tuning PID-I controller: Proceedings of the 18th IFAC World Congress. Milano, Italy, 2011, pp. 3635-3640.
4. *Pfeiffer B.-M.* Towards «plug and control»: self-tuning temperature controller for PLC, *International Journal of Adaptive Control and Signal Processing*, 2000, No. 14, pp. 519-532.
5. *Ziegler J., Nichols N.* Optimum settings for automatic controllers, *Trans. ASME*, 1942, No. 65, pp. 759-768.
6. *Shubladze A.M., Kuznetsov S.I.* Avtomaticheskii nastravayushchiesya promyshlennyye PI i PID regulatory [Automatically tunable industrial PI and PID controllers], *Avtomatizatsiya v promyshlennosti* [Automation in Industry], 2007, No. 2, pp. 15-17.
7. *Rotach V.Ya. Kuzishchin V.F., Petrov S.V.* Nastroyka regulyatorov po perekhodnym kharakteristikam sistem upravleniya bez ikh approksimatsii analiticheskimi vyrazheniyami [Controllers adjustment based on control system transient characteristics without their approximation with analytical expressions], *Avtomatizatsiya v promyshlennosti* [Automation in Industry], No. 11, 2009, pp. 9-12.
8. *Chen J., Huang T.* Applying neural networks to on-line updated PID controllers for nonlinear process control, *Journal of Process Control*, 2004, No. 14, pp. 211-230.
9. *Fang M., Zhuo Y., Lee Z.* The application of the self-tuning neural network PID controller on the ship roll reduction in random waves, *Ocean Engineering*, 2010, No. 37, pp. 529-538.
10. *Anderson K.L., Blankenship G.I., Lebow L.G.* A rule-based adaptive PID controller, *Proc. 27th IEEE Conf. Decision. Control*, 1988, pp. 564-569.
11. *Omatu S., Khalid M., Yusof R.* Neuro-Control and its Applications. London: Springer, 1995, 255 p.
12. *Reyes J., Astorga C., Adam M., Guerrero G.* Bounded neuro-control position regulation for a geared DC motor, *Engineering Applications of Artificial Intelligence*, 2010, No. 23, pp. 1398-1407.
13. *Tan S.-H., Hang C.-C., Chai J.-S.* Gain scheduling: from conventional to neuro-fuzzy, *Automatica*, 1997, Vol. 33, No. 3, pp. 411-419.
14. *Zhao Z.Y., Tomizuka M., Isaka S.* Fuzzy gain scheduling of PID controllers, *IEEE Transactions on systems, man, and cybernetics*, 1993, No. 5, pp. 1392-1398.
15. *Unal M., Ak A., Topuz V., Erdal H.* Optimization of PID Controllers Using Ant Colony and Genetic Algorithms. London: Springer, 2013, 85 p.
16. *Eremenko Yu.I., Poleshchenko D.A., Glushchenko A.I.* O primeneniі neyrosetevogo optimizatora parametrov PI-regulyatora dlya upravleniya nagrevatel'nymi pechami v razlichnykh rezhimakh raboty [About usage of PI-controller parameters neural tuner for control of heating furnaces functioning in different modes], *Upravlenie bol'shimi sistemami* [Large-Scale Systems Control], 2015, Issue 56, pp.143-175.
17. *Hagglund T., Tengvall A.* An automatic tuning procedure for unsymmetrical processes, *Proceedings of 3rd European control conference*, 1995, pp. 2450-2455.
18. *Eremenko Yu.I., Poleshchenko D.A., Glushchenko A.I., Fomin A.V.* Ob otsenke primenimosti razlichnykh struktur neyronnoy seti v realizatsii neyrosetevogo optimizatora parametrov PI-regulyatora dlya upravleniya teplovymi ob"ektami [On applicability estimation of different neural networks structures for implementation of PI-controller parameters neural optimizer for heating plants control], *Sistemy upravleniya i informatsionnye tekhnologii* [Management Systems and Information Technology], 2014, No. 3.2 (57), pp. 236-241.
19. *Hornik K., Stinchcombe M., White H.* Multilayer feed-forward networks are universal approximators, *Neural networks*, 1989, No. 2 (5), pp. 359-366.
20. *Huang G.B., Wang D.H., Lan Y.* Extreme learning machines: a survey, *International Journal of Machine Learning Cybernetics*, 2011, No. 2, pp. 107-122.

Статью рекомендовал к опубликованию д.ф.-м.н., профессор М.Е. Семенов.

**Еременко Юрий Иванович** – Старооскольский технологический институт им. А.А. Угарова (филиал) ФГАОУ ВПО НИТУ «МИСиС»; e-mail: erem49@mail.ru; 309516, г. Старый Оскол, м-н Макаренко, 42; тел.: 84725451210; кафедра автоматизированных и информационных систем управления; зав. кафедрой; д.т.н.; профессор.

**Полещенко Дмитрий Александрович** – e-mail: po-dima@yandex.ru; кафедра автоматизированных и информационных систем управления; к.т.н.; доцент.

**Глушченко Антон Игоревич** – e-mail: strondutt@mail.ru; кафедра автоматизированных и информационных систем управления; к.т.н.; доцент.

**Eremenko Yuri Ivanovich** – Sary Oskol technological institute n.a. A.A. Ygarov (branch) NUST "MISIS"; e-mail: erem49@mail.ru, 42, Makarenko microdistrict, 309516, Sary Oskol, Russia; phone: +74725451210; the department of automated and information control system; dr. of eng. sc.; professor.

**Poleshchenko Dmitry Alexandrovich** – e-mail: po-dima@yandex.ru; the department of automated and information control system; cand. of eng. sc.; associate professor.

**Glushchenko Anton Igorevich** – e-mail: strondutt@mail.ru; the department of automated and information control system; cand. of eng. sc.; associate professor.