

УДК 006.72

А. А. Воевода, Д. О. Романников

Новосибирский государственный технический университет

Метод синтеза регуляторов с использованием нейронных сетей для нелинейных объектов

Основными вариантами использования нейронных сетей для решения задач синтеза систем автоматического управления являются: использование их для корректировки значений коэффициентов регулятора; использование нейронного регулятора, при котором его обучение выполняется различными способами, в частности по заранее рассчитанным данным (ошибок и известного управления) или путем оптимизации с целью минимизации ошибки выходного сигнала объекта. Предлагается метод синтеза нейронного регулятора для нелинейных объектов на основе структуры предварительно рассчитанного регулятора для линеаризованной модели объекта. К основным шагам предлагаемого метода относятся: синтез регулятора для линеаризованной модели объекта; получение значений сигналов регулятора при моделировании с использованием сигнала «белого шума»; обучение нейронного регулятора; последовательное выполнение процедуры оптимизации и увеличение диапазона уставки до требуемых значений. Приводится пример применения методики на объекте модели угла отклонения θ объекта перевернутого маятника.

Нейронные сети, регулирование, замкнутые системы, нелинейные объекты, оптимизация

На сегодняшний день нейронные сети применяются для решения многих задач искусственного интеллекта, в частности для распознавания объектов на изображениях [1], распознавания и синтеза речи [2]; в [3] предложен алгоритм для реализации системы для игры в Altari, в [4] реализуется система для игры в Go, а в [5] предлагается методика построения нейронной сети для решения логико-арифметических задач с помощью синтеза структуры нейронной сети. Нейронные сети используются и для синтеза систем автоматического управления (например, [6], [7]).

Одно из направлений применения нейронных сетей для систем автоматического управления – их использование для настройки параметров значений регуляторов, в частности ПИД-регуляторов [8]. Структурная схема такого регулирования приведена на рис. 1, где v – уставка, e – ошибка, u – управление, y – выходное значение объекта.

При этом система (рис. 1) адаптивна, т. е. значения коэффициентов регулятора подстраиваются с течением времени при работе системы. Предпочтительнее, чтобы обучение нейронной сети выполнялось из начального устойчивого положения системы (обучение из начального неустойчивого положения системы приводит к существенным сложностям при процедуре оптимизации). К недостаткам данного способа управления относится ограниченность применения регуляторов в управлении нелинейными объектами, для которых расчет регуляторов часто является нерешенной задачей.

Другое направление заключается в реализации регулятора на нейронах, например [9] (рис. 2). На вход нейронной сети подаются векторы ошибок $\mathbf{E} = \{e_t, e_{t-1}, \dots, e_{t-n-1}\}$ и вектор выходного сигнала объекта $\mathbf{Y} = \{y_t, y_{t-1}, \dots, y_{t-m-1}\}$, где t – текущий момент времени, n , m – размерности векторов сигналов ошибок выходных сигналов




Рис. 1

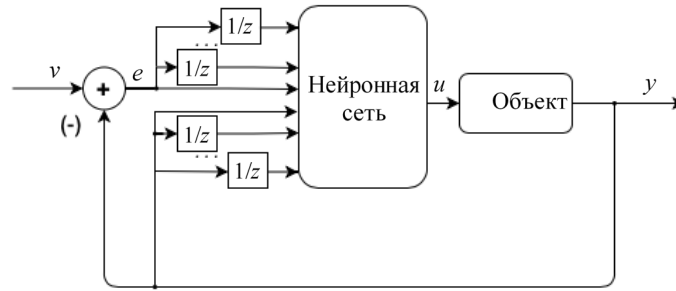


Рис. 2

соответственно. При этом в известных авторам публикациях структура нейронной сети задавалась либо сетью прямого распространения, либо долгой краткосрочной памятью (long-short term memory, LSTM) управляемых рекуррентных (gated recurrent unit, GRU) нейронов, а вопросы обоснования выбора количества нейронов и их нелинейностей остаются без ответов. При этом обучение нейронной сети может выполняться при помощи предварительно полученных данных для желаемого переходного процесса. Существенным недостатком такого направления служит процесс получения данных для обучения нейронной сети, в особенности для нелинейных объектов.

Еще одно направление синтеза нейронных регуляторов – способ управления по предсказанию (*predictive control*) [10]. Структурная схема этого способа управления (рис. 3) состоит из трех основных блоков: 1) объект управления; 2) блок регулятора; 3) нейронная сеть модели объекта. На вход блока оптимизации подается уставка v , а на выходе формируется два сигнала управления: вектор U' подается на нейронную модель объекта, на которую также приходит вектор сигнала с выхода объекта Y с задержкой в один такт. Далее в нейронной модели объекта формируется предсказание следующего значения объекта y' , которое подается на регулятор с целью дальнейшей оптимизации и формирования сигнала управления u для объекта.

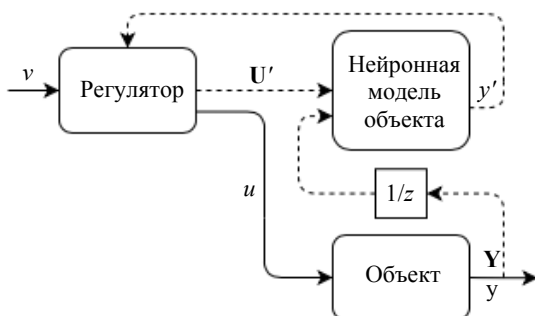


Рис. 3

Стоит отметить, что такой способ не получил развития на практике из-за возникающих ошибок при регулировании по причине погрешностей в нейронной модели объекта. Применение вышеуказанного метода ограничивается и процедурой оптимизации, затратной по времени и вычислительным ресурсам, которая должна выполняться во время процесса регулирования.

При синтезе систем автоматического управления применяют также и методы обучения с подтверждением (*reinforcement learning*) [11], в том числе и с использованием нейронных сетей. В [12] предложено использование однослойной нейронной сети в качестве нейронного регулятора для линейных объектов, а в [7], [13] – способы синтеза нейронных регуляторов для многоканальных объектов. Общий недостаток методов обучения с подтверждением применительно к задаче синтеза систем автоматического управления – это сложность обеспечения нейронным регулятором работы с поддержанием диапазона значений уставок. Так, в [13] уставка задавалась тремя фиксированными значениями. Также стоит заметить, что к недостаткам [7], [11], [13] относится то, что: 1) использование методов обучения с подтверждением гарантирует только теоретическую сходимость; 2) для части объектов с малой областью устойчивости процесс обучения может занимать значительное время.

Предлагается методика синтеза и обучения нейронного регулятора для нелинейных объектов с использованием рассчитанного регулятора для линеаризованной модели объекта с последующим переходом к нелинейному объекту. Предлагаемая методика рассмотрена на примере модели угла отклонения θ объекта перевернутого маятника.

Статья излагается в следующем порядке: сначала приводится постановка задачи, потом предлагается методика синтеза нейронного регулятора на основе предварительно синтезированного регулятора для линеаризованной модели объекта, а затем приводится пример синтеза системы авто-

матического управления для нелинейного объекта. Статья заканчивается выводами, в которых приведены основные результаты, а также рассуждения о направлении дальнейших исследований.

Постановка задачи. Синтез системы автоматического управления для нелинейного объекта, который может быть представлен в виде

$$y^{(n)} = F(y, \dot{y}, \ddot{y}, \dots, y^{(n-1)}, u),$$

где y – выходной сигнал объекта; u – сигнал управления.

Аналитических методов решения этой задачи в общем виде на данный момент нет. Существующие методы синтеза, например метод, в котором используется функция Ляпунова для определения управляющего воздействия, позволяют определять параметры регулятора для заданной структуры. Синтез систем методом линеаризации обратной связью предполагает, что нелинейную систему преобразуют к линейной с целью дальнейшего синтеза регулятора известными способами. Метод синтеза стабилизирующих законов управления путем декомпозиции заключается в независимом синтезе систем автоматического управления для отдельных частей и дальнейшем исследовании агрегированной синтезированной системы.

К недостаткам вышеприведенных методов можно отнести их сложность и ограниченность применения. С другой стороны, синтез систем автоматического регулирования для линейных объектов хорошо изучен. Тогда для класса линеаризуемых объектов сформулируем задачу разработки метода синтеза регулятора с использованием нейронных сетей для нелинейного объекта, в которой структура нейронной сети регулятора определяется структурой предварительно рассчитанного регулятора для линеаризованной модели соответствующего объекта с дальнейшим обобщением полученной структуры нейронного регулятора и обучения его для применения к регулированию исходного нелинейного объекта.

Метод синтеза нейронного регулятора. Для синтеза нейронного регулятора могут применяться разные методы. Рассматривается метод, при котором на вход нейронной сети подается сигнал ошибки, а на ее выходе формируется управляющее воздействие, которое затем подается на объект управления. При синтезе нейронного регулятора возникает ряд задач, а именно: формирование структуры нейронной сети, ее инициализация начальными значениями и процесс обучения.

В известных авторам публикациях в качестве структуры нейронной сети выбирают нейронные сети прямого распространения (feedforward neural networks) [13] или нейронные сети с LSTM- или GRU-нейронами во входном слое [14], при этом количество нейронов в слое и количество слоев выбирается исходя из опыта исследователя, а начальные условия задаются случайными значениями [11].

Обучение нейронной сети может происходить разными способами, например оптимизацией по различным критериям, в частности по наименьшей сумме квадратов ошибок для переходного процесса или по отклонению переходного процесса от желаемого. Также для динамических систем применяются и методы обучения с подкреплением, в частности применение метода Actor-Critic [7], [11], [13], [15] позволяет обучить нейронный регулятор для нелинейного объекта, но сопряжено со сложностью обеспечения регулирования в диапазоне значений уставок и проблемой сходимости обучения.

Рассмотрим нелинейный объект, для которого существует линейная модель. Для линейного объекта можно рассчитать регулятор, используя один из существующих методов синтеза. Предлагается выполнить преобразование из линейного регулятора в нейронную сеть и тем самым обосновать ее структуру, а именно: число входов и выходов, число слоев, количество нейронов в слоях и начальные значения весов. С целью обеспечения возможности регулирования для исходного нелинейного объекта требуется обобщить полученную нейронную сеть регулятора, выполнить ее обучение (далее *первое обучение*) для возможности регулирования при малых значениях переменных и обучение (далее *второе обучение*) для работы на больших значениях. Процесс обобщения и первого обучения – классический и не представляет особого интереса. При втором обучении могут возникать сложности при расходящихся переходных процессах. Методика, позволяющая выполнять обучение при расходящемся переходном процессе, заключается в итеративном процессе, первый шаг которого – моделирование и получение переходного процесса системы. На втором шаге выполняется «домножение» расходящейся функции ошибки на множитель (например, на пропорциональной экспоненте), чтобы привести ее к сходящемуся виду. Третьим шагом выполняется процесс оптимизации.

Основываясь на вышеуказанном, сформулируем *метод синтеза* нейронного регулятора для нелинейного объекта, исходя из его линеаризованной модели:

1. Переход к линеаризованной модели исходного объекта (при малых значениях переменных).

2. Синтез линейного регулятора для линеаризованной модели согласно одному из известных методов.

3. Преобразование из непрерывного представления объекта и регулятора в дискретное, которое может быть выполнено разными способами, в частности преобразованием с использованием различных методов, реализованных в программных пакетах, к примеру MatLab, или заменой непрерывных интеграторов на дискретные. При этом следует убедиться, что переходные процессы в непрерывном и соответствующем ему дискретном вариантах отличаются на допустимое значение (выбирается исходя из конкретной задачи и регулируется за счет уменьшения шага дискретизации).

4. Преобразование линейного дискретного регулятора в нейронный при помощи следующих действий:

– входные и выходные сигналы со схемы регулятора преобразуются во входные и выходные нейроны в нейронной сети – например, сигнал ошибки регулятора преобразуется в входной нейрон, а сигнал управления регулятора в выходной нейрон;

– сигналы, которые формируются на входе звеньев задержки регулятора, преобразуются в выходные нейроны нейронной сети;

– сигналы, которые формируются на выходе звеньев задержки регулятора, преобразуются во входные нейроны нейронной сети;

– сумматоры заменяются на нейроны с линейными функциями активации и с весами с соответствующими значениям на связях в исходной схеме регулятора.

5. Обобщение структуры полученной нейронной сети выполняется за счет увеличения количества нейронов в слоях.

6. Получение массива значений (переходного процесса) ошибки e , управления u , элементов задержек регулятора z^{-1} выполняется при помощи задачи задающего воздействия «белый шум».

7. Обучение обобщенной нейронной сети одним из методов обучения на базе полученного массива данных таким образом, чтобы переходные

процессы в системе с нейронным и дискретным регуляторами различались на допустимое значение (выбирается, исходя из конкретной задачи).

8. Определение максимальной амплитуды задания V_{\max} , при которой полученный нейронный регулятор способен обеспечить желаемый переходный процесс для системы с нелинейным объектом.

9. Последовательное выполнение следующей процедуры до достижения требуемых значений задания:

а) задание текущего значения задания V_{curr} (начальное значение для задания следует получить с п. 8) и значений увеличения задания step ;

б) формирование последовательности значений задания в диапазоне $\{0, V_{\text{curr}} + \text{step}\}$;

в) выполнение моделирования и процедуры оптимизации полученной системы. Если процедура не была успешна (расходящийся процесс), то задать $\text{step} = \text{step}/2$ и вернуться на п. 9, б; если процедура была успешна и требуемые значения уставок (с допустимой ошибкой) достигнуты, то завершить обучение; иначе вернуться на п. 9, б.

Пример синтеза нейронного регулятора.

Предлагаемый метод проиллюстрируем на примере задачи синтеза регулятора для модели объекта угла отклонения θ перевернутого маятника на цилиндре для диапазона уставок $\{0, 1\}$, движение которого описывается уравнением

$$\left[1 - \frac{ml}{(M+m)L} \cos^2 \varphi\right] \ddot{\varphi} - \frac{g}{L} \sin \varphi + \frac{I}{(M+m)L} \sin \varphi \cos(\varphi^2) = -\frac{ml}{(M+m)L} \cos(\varphi u), \quad (1)$$

где m – масса маятника; M – масса цилиндра; l – длина маятника до центра тяжести; φ – отклонение маятника от вертикали; u – сила, приложенная к цилиндру; I – момент инерции маятника относительно центра тяжести; $L = (I + ml^2)/ml$ (полное описание модели приведено в [14]).

Для возможности формирования структуры нейронной сети объект, определяемый (1), преобразован в дискретное представление заменой непрерывных интеграторов на дискретные $0.01/(z-1)$ с временем дискретизации 0.01 с (команда $c2d(tf([1], [1 \ 0]), 0.01)$ в MatLab) и проверкой того, что отличие между переходными процессами в непрерывном и дискретном видах не больше 5%. Представление объекта в дискретном виде приведено в нижней части рис. 6.

Для рассматриваемого объекта (1) используем линеаризованную модель [14], у которой переходные процессы будут совпадать с достаточной степенью точности – при малых углах отклонения φ (в пределах 30°): $\sin \varphi \approx \varphi$, $\cos \varphi \approx 1$. Линеаризованная модель объекта имеет вид

$$W_o(s) = -\frac{1}{s^2 - 5}. \quad (2)$$

Структура объекта (2) в дискретном виде представлена на рис. 4.




Рис. 4

Для полученной линеаризованной модели можно синтезировать регулятор одним из классических способов, например в [16] приведен расчет регулятора полиномиальным методом синтеза. Полученная передаточная функция в непрерывном виде выглядит следующим образом:

$$W_r(s) = \frac{-0.248s^2 - 0.96s - 1}{0.0016s^2 + 0.032s}, \quad (3)$$

а соответствующая схема в дискретном виде представлена в верхней части рис. 5.

От регулятора с использованием оператора z^{-1} с применением правил преобразования (метод синтеза, п. 4) выполнен переход к регулятору на нейронах (рис. 6).




Рис. 6

Полученная нейронная сеть регулятора состоит из двух скрытых слоев по одному нейрону в каждом: S2 в первом и S1 во втором, с линейными функциями активации, в соответствии с сумматорами в исходном регуляторе. Начальные значения весов нейронной сети соответствуют значениям звеньев усиления в исходном регуля-

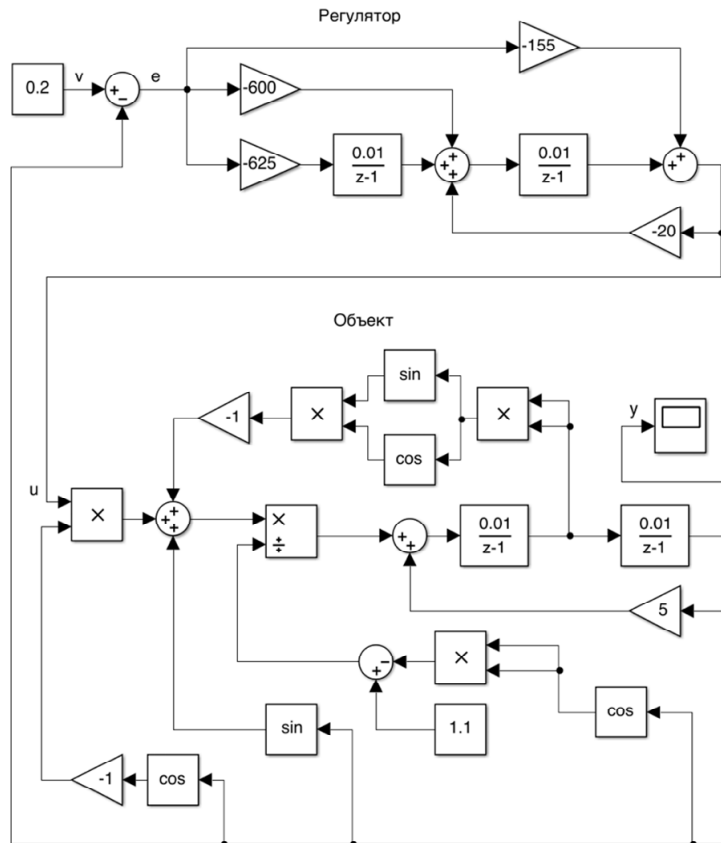


Рис. 5

торе. Нейронная сеть согласно правилам преобразования содержит три входных (два входа для сигналов со звеньев задержек и вход сигнала ошибки) и три выходных (два выхода для сигналов для формирования значений звеньев задержек и выход сигнала управления) нейрона.

Итоговая система с нейронным регулятором устойчива и выдает приемлемый переходный процесс при уставке до 0.35. После получения структуры нейронной сети регулятора необходимо выполнить ее обобщение, добавляя нейроны с нелинейными функциями активации.

Следующий шаг – моделирование полученной системы подачей сигнала «белого шума» на ее вход и получением массива со значениями ошибки регулирования, управления и значений сигналов на элементах задержки регулятора. При помощи полученных данных (массив из 5000 элементов) была обучена обобщенная нейронная сеть регулятора (рис. 7).

Обобщенная нейронная сеть регулятора состоит из трех входных и трех выходных нейронов, а также двух скрытых слоев. В качестве функций активации нейронов проводились эксперименты с функциями активации «выпрямитель» (relu) и гиперболический тангенс (tanh); существенной разницы не было обнаружено. При обобщении нейронной сети регулятора в двух скрытых слоях использовались по 50 и 30 нейронов соответственно. Обучение выполнялось по критерию суммы квадратов ошибок и при помощи метода адаптивной оптимизации Adam (A Method for Stochastic Optimization) за 74 000 эпох, значение коэффициента обучения 0.001, остальные параметры оставлены без изменений.




Рис. 7

После обучения нейронной сети регулятора согласно предлагаемому методу была выполнена итеративная процедура оптимизации с постепенно увеличивающимися границами диапазона уставки. При этом осуществлялась итеративная процедура, при которой на первом шаге моделировалась полученная система, а на втором – выполнялась процедура оптимизации. Для моделирования переходного процесса случайным образом была составлена последовательность уставок из 10 различных значений, которая также включала в себя и максимальные значения текущего диапазона. Длина переходного процесса была задана в 500 тактов моделирования с длиной одного такта в 0.01, что соответствует времени дискретизации объекта и регулятора. В процессе обучения диапазоны уставок v менялись следующим образом: $\{0, 0.35\}$, $\{0, 0.55\}$, $\{0, 0.65\}$, $\{0, 0.7\}$, $\{0, 0.75\}$, $\{0, 0.8\}$, $\{0, 0.825\}$, $\{0, 0.85\}$, $\{0, 0.875\}$, $\{0, 0.9\}$, $\{0, 0.925\}$, $\{0, 0.95\}$, $\{0, 0.975\}$, $\{0, 1.0\}$ (нижняя граница диапазона была зафиксирована).

На рис. 8 приведен пример переходных процессов при уставках $\{0.3, 0.6, 0.9, 1.0, 0.9, 0.6, 0.3\}$: на оси ординат указано выходное значение объекта, по оси абсцисс – номера шагов моделирования, где каждый шаг равен 0.01 с.

По переходным процессам, приведенным на рис. 8, можно сделать следующие выводы: 1) все процессы сходящиеся; 2) максимальная уставка – 1.0, т. е. полученный регулятор способен выполнять стабилизацию в требуемом диапазоне значений; 3) графики переходных процессов – колебательные с сильным первым выбросом до 90 %. Стоит заметить, что колебательный характер переходного процесса обуславливается тем, что в рассчитанном регуляторе для линеаризованного объекта (или для соответствующего нелинейного объекта при малых углах отклонения) переходный процесс также является колебательным.

Предложен метод синтеза нейронного регулятора для управления нелинейных линеаризуемых (в малом) объектов, в которых структура нейронной сети регулятора определяется структурой предварительно рассчитанного регулятора для линеаризованной модели соответствующего объекта. Новизна предлагаемого метода состоит в том, что синтез нейронного регулятора выполняется на основании структуры регулятора, полученного классическим способом, который используется для определения структуры, а именно: количества слоев, входных и выходных нейронов, а также начальных значений и количеств, струк-




Рис. 8

туры для необобщенного варианта нейронного регулятора. Основными шагами предлагаемого метода являются: синтез регулятора одним из известных методов синтеза для линеаризованной модели нелинейного объекта; преобразование структуры полученного регулятора в нейронный регулятор согласно предложенным правилам преобразования и дальнейшее его обобщение с целью регулирования исходного нелинейного объекта; обучение нейронного регулятора для работы при малых углах отклонения и обучение для работы на больших значениях задания (уставки), в

том числе и значениях, на которых система с классическим регулятором неустойчива. Предложенный метод проиллюстрирован на примере задачи синтеза регулятора для модели угла отклонения θ перевернутого маятника на цилиндре.

Дальнейшим планируемым развитием предлагаемого метода является формализация процедуры обобщения нейронной сети, полученной путем преобразования регулятора, и обоснование выбора начальных значений в обобщенной нейронной сети регулятора.

СПИСОК ЛИТЕРАТУРЫ

1. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks // Neural Information Processing Systems (NIPS). 2012. Vol. 30, № 6. P. 1097–1105.
2. Graves A., Mohamed A., Hinton G. E. Speech recognition with deep recurrent neural networks // Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP). Vancouver, BC, 2013. P. 6645–6649.
3. Playing Atari with Deep Reinforcement Learning / V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra, M. Riedmiller // URL: <https://arxiv.org/abs/1704.03732> (дата обращения 27.09.2020).
4. Mastering the game of Go with deep neural networks and tree search / D. Silver, A. Huang, C. Maddison, A. Guez, L. Sifre, G. Driessche, J. Schrittwieser, I. Antonoglou, V. Panneershelvam, M. Lanctot, S. Dieleman, D. Grewe, J. Nham, N. Kalchbrenner, I. Sutskever, T. Lillicrap, M. Leach, K. Kavukcuoglu, T. Graepel, D. Hassabis // Nature 2016. № 529. P. 484–503.
5. Воевода А. А., Романников Д. О. Синтез нейронной сети для решения логико-арифметических задач // Тр. СПИИРАН. 2017. Вып. 54. С. 205–223.
6. Макаров И. М., Лохин В. М. Интеллектуальные системы автоматического управления. М.: Физматлит, 2001.
7. Воевода А. А., Романников Д. О. Синтез регуляторов для многоканальных систем с использованием нейронных сетей // Науч. вестн. Новосибирского гос. техн. ун-та. 2019. № 4. С. 7–16.
8. An adaptive PID neural network for complex nonlinear system control // J. Kang, W. Meng, A. Abraham, H. Liu // Neurocomputing. 2014. Vol. 135. P. 79–85.
9. Белов М. П., Чан Д. Х. Интеллектуальный контроллер на основе нелинейного оптимального управления роботами-манипуляторами // Изв. СПбГЭТУ «ЛЭТИ». 2018. № 9. С. 76–86.
10. Soloway D., Haley P. J. Neural generalized predictive control // Proc. of the 1996 IEEE Intern. Symp. on Intelligent Control, Dearborn, MI, USA, 1996. P. 277–282.
11. Sutton R., Barto A. Reinforcement learning: An introduction. Cambridge: MIT Press, 2018.
12. Lewis F. L., Vrabie D., Vamvoudakis K. G. Reinforcement learning and feedback control: Using natural decision methods to design optimal adaptive controllers // IEEE Control Systems Magazine. 2012. Vol. 32, № 6. P. 76–105.
13. Yuan W., Kirubakaran V., Biao H. A novel approach to feedback control with deep reinforcement learning // 10th IFAC Symp. on Advanced Control of Chemical Processes ADICHEM. Shenyang, China, 2018. Vol. 51, iss. 18. P. 31–36.

14. Воевода А. А., Бобобеков К. М. Автономность и астатизм в многоканальной системе с двухпараметрическим регулятором // Сб. науч. тр. НГТУ. 2017. № 3 (89). С. 7–31.

15. Deep Q-learning from demonstrations. Available / T. Hester, M. Vecerik, O. Pietquin, M. Lanctot, T. Schaul, B. Piot, D. Horgan, J. Quan, A. Sendonaris, G. Dulac-

Arnold, I. Osband, J. Agapiou, J. Z. Leibo, A. Gruslys // URL: <https://arxiv.org/abs/1704.03732> (дата обращения 27.05.2020).

16. Бобобеков К. М., Воевода А. А. Расчет параметров регулятора для стабилизации перевернутого маятника по углу отклонения // Сб. науч. тр. НГТУ. 2016. № 3 (85). С. 18–32.

A. A. Voevoda, D. O. Romannikov
Novosibirsk State Technical University

SYNTHESIS METHOD OF REGULATORS USING NEURAL NETWORKS FOR NONLINEAR OBJECTS

The main options for using neural networks to solve the problems of synthesis of automatic control systems are: using them to adjust the values of controller coefficients; the use of a neural controller, in which its training is carried out in various ways, in particular, according to pre-calculated data (errors and known control) or by optimization in order to minimize the error of the output signal of the object. A method for synthesizing a neural controller for non-linear objects based on the structure of a previously calculated controller for a linearized model of an object is proposed. The main steps of the proposed method are: synthesis of a controller for a linearized model of an object; obtaining the values of the controller signals during modeling using the «white noise» signal; training a neural regulator; successively performing the optimization procedure and increasing the setpoint range to the required values. An example of applying the methodology on an object of a model of the angle of deviation θ of an object of an inverted pendulum is given.

Neural networks, regulation, closed systems, nonlinear objects, optimization

УДК 007.3

Н. А. Назаренко, П. И. Падерно
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

Комплексные автоматизированные системы управления: подход к определению численности и квалификации операторов

Проведены комплексное исследование и всесторонний анализ возможных подходов к определению численности и квалификации операторов, действующих в условиях необходимости обработки большого количества разнородных задач. Предложен способ классификации задач и обрабатываемых их операторов, позволяющий в качестве начальной итерации распределить операторов по типам задач. Основной особенностью предлагаемого подхода является его ориентация на оценку и повышение эффективности функционирования комплексных автоматизированных систем управления с точки зрения максимизации получаемого дохода с учетом необходимых расходов и штрафов. На основе использования теории систем массового обслуживания получен ряд аналитических выражений и графических зависимостей, позволяющих в какой-то мере оценить необходимую численность и квалификацию операторов при решении конкретных задач в зависимости от имеющихся исходных данных. Указаны преимущества и возможные границы использования предлагаемого подхода. Результаты показали, что данный подход целесообразно использовать на ранних этапах разработки комплексных автоматизированных систем управления.

Автоматизированные системы управления, определение численности операторов, определение квалификации оператора, системы массового обслуживания, проектирование автоматизированных систем управления

На ранних этапах проектирования современных комплексных автоматизированных систем управления (КАСУ) различного назначения перед разработчиком в соответствии с требованиями
