

УДК 681.5

НЕЙРОКОНТРОЛЛЕР ОЦЕНКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭЛЕКТРОМЕХАНИЧЕСКИХ СИСТЕМ

Веселов О.В., Светушенко С.Г.*ФГБОУ ВПО «Владимирский государственный университет им. Александра Григорьевича
и Николая Григорьевича Столетовых», Владимир, e-mail: 010848_j@mail.ru*

Обеспечение стабильности качества производимой продукции напрямую зависит от технического состояния оборудования, на котором оно производится. Среди возможных дефектов, приводящих к нарушению режимов работы объекта, параметрические вносят существенный деструктивный вклад в выходные параметры. Выявить источник возникновения дефекта вплоть до элемента возможно с использованием нейроконтроллера. Используя возможности нейросетей, строится такой алгоритм диагностики, который точно определяет вид и параметры сигнала в каждой контрольной точке объекта диагностики, классифицирует его и на основании полученной классификации определяет причину, степень неисправности и неисправный элемент. Контроллер включает в себя набор типовых нейронных модулей, каждый из которых содержит набор нейронных блоков. Принцип работы основан на использовании последовательного анализа параметров выявленного дефектного устройства для установления элемента, вызвавшего дефект. Для этого используются радиально базисные нейронные сети, которые обучаются на основе созданной базы данных в результате моделирования. Данные для обучения получены на основе моделирования виртуальной модели привода. Работа алгоритма рассматривается на примере регулятора скорости привода постоянного тока. Приведена методика построения нейроконтроллера для диагностики ЭМС. В зависимости от задачи можно варьировать точность оценки параметров в широких пределах.

Ключевые слова: электромеханическая система, диагностика, алгоритм, нейронные сети, нейроконтроллер, моделирование

NEUROCONTROLLER FOR THE ESTIMATION OF TECHNICAL STATE OF ELECTROMECHANICAL SYSTEMS

Veselov O.V., Svetushenko S.G.*Vladimir State University named after Alexander Grigoryevich and Nikolay Grigoryevich Stoletov,
Vladimir, e-mail: 010848_j@mail.ru*

Ensuring stability of quality of produced goods depends directly on technical condition of equipment used for their manufacture. Among the possible defects that lead to a violation of the modes of the object, parametric ones make a significant destructive contribution to the output parameters. It is possible to identify the source of the defect down to the element using a neurocontroller. Using the capabilities of neural networks, we build such a diagnostic algorithm, which accurately determines the type and parameters of the signal in each control point of the diagnostic object, classifies it, and based on the resulting classification determines the cause, degree of failure and the faulty element. The controller includes a set of typical neural modules, each containing a set of neural blocks. The working principle is based on a sequential analysis of the parameters of a detected defective device in order to identify the element that caused the defect. Radially based neural networks are used for this purpose, which are trained on the basis of the created database as a result of simulation. The data for training are obtained from the simulation of a virtual drive model. The work of the algorithm is considered on the example of a direct current c motor drive speed regulator. A method for building a neurocontroller for EMC diagnostics is presented. Depending on the task, you can vary the accuracy of parameter estimation within a wide range.

Keywords: electromechanical system, diagnostics, algorithm, neural networks, neurocontroller, modeling

Электромеханические системы автоматических и автоматизированных систем для поддержания требуемых характеристик нуждаются в оценке их фактического состояния, особенно для систем с ограниченным доступом в обслуживании или с полным его отсутствием. Во всех случаях оценка состояния выполняется с использованием специализированных систем и алгоритмов диагностирования.

Уровень сложности решаемой задачи в первую очередь определяется особенностями функционирования диагностируемой системы и той задачей, которую возлагают на диагностическую систему. При этом следует учитывать уровень детализации объек-

та, причины и виды дефектов, возможность измерения входных и выходных сигналов, конструктивные соображения и т.п.

Решение подобных задач в теоретическом плане достаточно полно представлено в трудах П.П. Пархоменко, Е.С. Сагомоняна, А.В. Мозгалевского, Д.В. Гаскарова, Л.П. Глазунова, С.П. Ксенза, А.В. Каляева, И.А. Биргера, Т.В. Алексеева, П.С. Давыдова, Я.З. Ципкина и др. и множеством технических решений [1, 2]. Показано, что системы диагностирования и алгоритмы постановки диагноза достаточно хорошо разработаны, но существует специфика, связанная с областью применения и особенностями функционирования. Заметим, что большин-

ство известных систем не учитывают особенности выполнения диагностических мероприятий, связанных с выявлением места и элемента при автономной работе систем диагностирования. Кроме того с повышением требований к качеству изделий известные алгоритмы не в состоянии обеспечить качественный диагноз и нуждаются в модификации или полной замене.

Последнее предполагает решение ряда задач, связанных с анализом полученной информации, реализацией выводов и принятия решения об использовании объекта по назначению в особых режимах функционирования, вплоть до остановки. Тогда содержанием алгоритмов диагностирования и, как следствие, управления техническим состоянием систем могут быть методы искусственного интеллекта.

Заложенные еще в прошлом столетии основы искусственного интеллекта в настоящее время с развитием электроники и средств вычислительной техники получили новые возможности. Использование методов искусственного интеллекта отражено в теоретических работах Г.С. Поспелова, Г.С. Осипова, С.В. Емельянова, В.М. Глушкова, М.Г. Гаазе-Рапопорта, Я.З. Ципкина, Э.В. Попова и зарубежных ученых Ф. Розенблатта, У. Питтса, Д. Перла, Н. Хомский, М. Ли Мински, А. Заде и др. [3–5].

Большинство работ посвящено теоретическим исследованиям в области искусственного интеллекта, включая нейронные сети и нечеткую логику. Однако в области практического применения удельный вес публикации относительно мал.

Можно указать на два возможных подхода в реализации систем диагностики на основе искусственного интеллекта: создание оригинальных нейронных сетей или применение известных, уже зарекомендовавших себя.

Используя возможности нейросетей, необходимо построить такой алгоритм диагностики, который точно определял бы вид

и параметры сигнала в каждой контрольной точке объекта диагностики, смог бы его классифицировать и на основании полученной классификации определить причину, степень неисправности и неисправный элемент.

Материалы и методы исследования

Цель управления движением представим неравенством вида $e(t) \leq \varepsilon$, $t \in [t_0, t_T]$, где $e(t) = x(t, x_0, u) - x_p(t)$ – динамическая ошибка, а параметр $\varepsilon > 0$ определяет требуемую точность осуществления движения. Допустимыми считаются сигналы, все параметры которых принадлежат области их допустимых значений. Если же значение хотя бы одного из указанных параметров выходит за область его допустимых значений, то сигналы считаются недопустимыми, следовательно, и вся система находится в состоянии, не соответствующем использованию по назначению. Оценить состояние объекта, найти дефект и принять решение о дальнейшем использовании можем с использованием нейронных сетей. Для этого необходимо выполнить анализ свойств объекта диагностирования, создать базу данных возможных дефектов, на основе которой создается база знаний, определить тип нейронной сети, настроить ее параметры на основе созданной базы знаний и выполнить исследования.

В качестве объекта будем рассматривать ПИ-регулятор скорости привода постоянного тока, упрощенная схема которого представлена на рис. 1.

Возможное изменение параметров регулятора (постоянной времени и коэффициента усиления) способно вызвать параметрический дефект, и при определенных обстоятельствах развитие такого дефекта может привести к критическому состоянию. В этом случае необходимо установить источник возникновения дефекта, для чего введем критерий обнаружения неисправности в электромеханической системе вида (*).

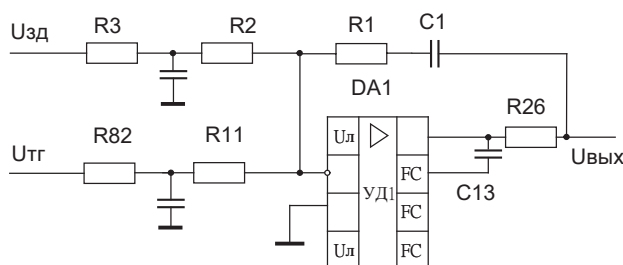


Рис. 1. Регулятор скорости

$$d = \begin{cases} 1, & \text{если } e(t) > \varepsilon \\ 0, & \text{если } e(t) \leq \varepsilon \end{cases} \quad (*)$$

Это неравенство разбивает пространство диагностических признаков x_1, x_2, \dots, x_n на множества Ω_1 – множество исправных состояний (при $d = 0$) и Ω_2 – множество неисправных состояний (при $d = 1$). Определение этих состояний и их принадлежности множествам (классам) Ω_1 или Ω_2 осуществляется путём проверки в реальном времени критерия обнаружения неисправности и фиксации моментов времени t_1, t_2, \dots, t_n , в которые нарушается целевое неравенство. Для распознавания типа дефекта, вызвавшего неисправное состояние, необходимо дополнительно определить диагностические признаки и синтезировать диагностические правила, принимающие на неисправных состояниях $x(t_1), x(t_2), \dots, x(t_n)$ значения, соответствующие типу дефекта. Для этого множество Ω_1 разбивается на кластеры в специально сконструированном пространстве, метрика которого такова, что в один кластер попадают объекты, близкие друг другу с точки зрения этой метрики.

Множество Ω_1 представим в виде двух подмножеств: подмножество k характеризуется функцией принадлежности $K(x_1)$, с множеством пар

$\{x^k \mid \mu_k(x_1), \forall x^k \in \Omega_1\}$ описывающих коэффициент усиления регулятора скорости и подмножество τ которое характеризуется функцией принадлежности $\mu_\tau(x_1)$, с множеством пар $\{x^\tau \mid \mu_\tau(x_2), \forall x^\tau \in \Omega_1\}$ описывающих постоянную времени регулятора. Выделяем кластеры, для которых будем создавать обучающие множества, отражающие диапазоны, в которых регулятор находится либо в идеальном состоянии, либо в допустимой зоне, либо на границе работоспособности (рис. 2). Каждый из кластеров дополнительно разбивается так, чтобы обеспечить выполнение условия (*) с заданной точностью.

Целенаправленный сбор обучающих данных можно выполнить двумя путями:

измерять параметры на реальном объекте, что не всегда осуществимо, или использовать виртуальную модель привода, максимально близко реализующую схемотехнику реального привода.

Второй путь является предпочтительным, поскольку позволяет создавать условия, которые невозможно реализовать на реальном объекте из-за возможной его поломки. Кроме того, известно, что любое явление, происходящее в приводе, отражается в выходном сигнале и важно связать его с внутренними изменениями. Созданная таблица (табл. 1) отображает тенденции в изменении параметров регулятора при изменении величин элементов схемы и является по существу источником для создания базы данных. Изменяя номиналы элементов R1, R2, C в соответствии с таблицей, получаем данные для создания базы знаний. Для этого измеряем сигналы с выхода регулятора при изменении K в большую и меньшую сторону при неизменной постоянной времени T регулятора и, наоборот, при изменении T, но при неизменном коэффициенте усиления K. Также при изменении K и T одновременно. Важно, чтобы при анализе постоянной времени в случае с изменением величины емкости данные сохранялись таким образом, чтобы соответствовали значениям величин резисторов. И, кроме того, в каждом случае при снятии сигнала числовые значения K и T выбираем таким образом, чтобы в обучающем векторе присутствовали требуемые, допустимые и опасные значения K и T.

Заметим, что сбор информации можно выполнять с любой точки привода, доступной для измерений. Обобщенным сигналом, несущим максимальное количество информации, является скорость перемещения исполнительного объекта. Единственным сдерживающим фактором является наличие нескольких одностипных регуляторов.




Рис. 2. Границы зон соответствия

Таблица 1

Предпосылки и заключения

Предпосылки			Заключения		Кластер
C1	R1	R2	K	T	Номер
<i>PS</i>	<i>NB</i>	<i>PS</i>	<i>PB</i>	<i>PB</i>	1
–	<i>NB</i>	<i>PS</i>	<i>PB</i>	<i>PS</i>	1
–	<i>NB</i>	–	<i>PB</i>	–	1
–	<i>NB</i>	<i>NS</i>	<i>PB</i>	<i>NS</i>	1
<i>NS</i>	<i>NB</i>		<i>PB</i>	<i>NB</i>	1
–	–	<i>PS</i>	<i>PS</i>	<i>PS</i>	2
–	<i>NS</i>	–	<i>PS</i>	–	2
–	<i>NS</i>	<i>NS</i>	<i>PS</i>	<i>NS</i>	2
<i>PS</i>	<i>PS</i>	<i>PS</i>	<i>PS</i>	<i>PB</i>	2
<i>NS</i>	<i>NB</i>	<i>NS</i>	<i>PS</i>	<i>NB</i>	2
<i>PS</i>	<i>NS</i>	<i>PS</i>	–	<i>PB</i>	3
–	<i>NS</i>	<i>PS</i>	<i>NS</i>	<i>PS</i>	3
–	<i>PS</i>	–	<i>NS</i>	–	3
–	–	<i>NS</i>	<i>NS</i>	<i>NS</i>	3
<i>NS</i>	–	<i>NS</i>	<i>NS</i>	<i>NB</i>	3
–	<i>PB</i>	<i>PS</i>	<i>NB</i>	<i>PS</i>	4
–	<i>PB</i>	–	<i>NB</i>	–	4
–	<i>PS</i>	<i>NS</i>	<i>NB</i>	<i>NS</i>	4
<i>NB</i>	<i>PS</i>	<i>NB</i>	<i>NB</i>	<i>NB</i>	4
<i>NB</i>	–	–	–	<i>NB</i>	4

Примечание: P – превышение, N – уменьшение, S – малое, B – большое, PB – превышение большое, PS – превышение малое, NB – уменьшение большое, NS – уменьшение малое.

Организационная структура процесса диагностирования приведена на рис. 3. Назначение блоков в данной структуре имеет следующее содержание. Блок оценки коэффициента усиления (NS1) выполняет функцию предварительного анализа текущего состояния электромеханической системы и вырабатывает сигнал управления коммутатором MUX.

Основная функция блока точной оценки коэффициента усиления в зоне B2 (B3,...,Bn) заключается в том, чтобы оценить коэффициент усиления с такой точностью, чтобы ее хватало для оценки постоянной времени сигнала с регулятора.

Функцией блока анализа K в зоне B2 является обработка информации с нейросетей точной оценки и передача мультиплексору оценки постоянной времени кода о найденном коэффициенте усиления. Функцией блока является и передача кода на мультиплексор вспомогательных нейросетей оценки коэффициента передачи о необходимости доопределить K.


Задача мультиплексора вспомогательных нейросетей оценки коэффициента – это

передача сигнала с регулятора на вход одной из вспомогательных нейросетей оценки K по сигналу от блока оценки K в зоне B2. Роль мультиплексора выполняет блок логического анализа A, который перенаправляет процесс передачи информации, связывая входы и выходы или выводит конкретное значение результата оценки параметра в рассматриваемой зоне. Вспомогательные нейросети необходимы для оценки K с более высокой точностью.

Блок анализа результатов работы вспомогательных нейросетей обрабатывает информацию со вспомогательных нейросетей и передает мультиплексору MUXt оценки постоянной времени код о найденном коэффициенте усиления.

Передача сигнала с регулятора на вход одного из трех блоков точной оценки K осуществляется мультиплексором.

Коммутатор дефектов K, объекта диагностики, по сигналу приходящего с сумматора или от мультиплексора оценки K, активизирует тот информационный экран, в котором содержится сообщение о виде и степени дефекта.



Принцип работы заключается в следующем. Считывается сигнал скорости снимаемого с датчика привода. Этот сигнал одновременно поступает на все нейронные сети контроллера. Нейронная сеть NS1 выполняет анализ кластера, в котором находится ЭМС в текущий момент времени. На основании этой информации происходит выбор нужного кластера B1, B2–Bn путем переключения выходов с использованием коммутатора MUX, и оценивается величина коэффициента усиления регулятора с использованием НС NS2-1 (в зависимости от кластера). Если достаточно точности оценки коэффициента, т.е. неравенство (*) выполняется, то MUXk подключает нейронную сеть оценки постоянной времени NS1-1 с использованием коммутатора MUXt.

Если в базе знаний не находится прямого соответствия между коэффициентом усиления и постоянной времени, то MUXk передает управление на сеть уточненной оценки величины K и затем вновь подключается НС оценки постоянной времени. В результате через коммутатор K выводятся величины коэффициента усиления и постоянной времени регулятора. В зависимости от заданной точности возможно подключение НС NS2-3 следующего уровня для более точной оценки параметров регулятора. По существу оценка параметров с точностью до 0,01 вполне удовлетворительная. Поэтому в структуре контроллера представлены три уровня НС.

Результаты исследования и их обсуждение

Проверка работоспособности проводилась на основе моделирования работы рассмотренного контроллера с использованием Matlab в двух вариантах. В первом варианте с использованием Simulink и NNTool была построена структура контроллера. Во втором с использованием возможности программирования в нотациях Matlab были написаны программные коды, полностью реализующие цикл работы диагностической системы, начиная с обучения и заканчивая установлением дефекта в объекте. И в том и в другом случае собираются обучающие данные с объекта, которые имеют общие подходы, но различную реализацию.

Учитывая особенности принятого принципа работы НС, выполнялся сбор данных с использованием виртуальной модели привода постоянного тока [6]. Сбор данных для обучения – достаточно трудоемкая работа, потребовавшая написания программных кодов и создания модели структуры. Учитывая, что реальная система должна работать в темпе работы диагностируемого

оборудования, возник вопрос об объеме обучающих выборок и длин обучающих векторов $\mathbf{x}_i = [\mathbf{x}_{i,1}, \mathbf{x}_{i,2}, \dots, \mathbf{x}_{i,p}]$. При этом необходимо учитывать способ ввода информации с реального объекта, такт квантования сигнала и разрядность вводимой информации. В модели использовали структуру, содержащую фиксатор нулевого порядка, запоминающее устройство и преобразователь двухстрочного вектора в вектор-строку.

Нейронные сети обладают различной способностью к кластеризации. Какие-то сети менее эффективны (например, персептрон), другие более эффективны (например, РБФ-сети). Поэтому выбор сети и проверка ее способности к кластеризации используемых данных в рамках решаемой задачи важны. Оценкой результата обучения будет ошибка равная $e = \max |d_i - F(\mathbf{x}_p, \mathbf{w})|$. Здесь d_i – известный выходной сигнал динамической системы. $F(\mathbf{x}_p, \mathbf{w})$ – функция преобразования входного сигнала динамической системой и этап измерения, связанный с вычислением выходного сигнала нейронной сети по известным входным сигналам и коэффициентам нейронной сети: $y_i = F(\mathbf{x}_p, \mathbf{w})$. При этом следует учесть, что ошибка может иметь не единственный локальный минимум. В результате обучения ошибка допустима, поэтому изменять структуру нейронной сети, усложнять ее, увеличивать число нейронов или слоев нет необходимости. В процессе моделирования лучшие результаты получены с использованием вероятностных нейронных сетей. Нейронная сеть первого уровня NS1 имеет 101 нейрон внутреннего слоя и 5 нейронов в выходном слое, что соответствует пяти рассматриваемым состояниям. Такое число элементов в используемой сети уменьшает число нейронов, с одной стороны, и увеличивает быстроедействие, с другой. Число оцениваемых состояний может быть любым и определяется поставленной задачей.

Собранные данные объединяются в матрицы, и каждой из них ставится в соответствие матрица векторов целей, образуя при этом пары векторов $\{\mathbf{x}_p, \mathbf{y}_i\}$. Вектор целей \mathbf{y}_i формируется на основе технических характеристик, приведенных в документации. Таким образом, объекты оказываются однозначно распределенными по четким классам.

Все нейронные сети в контроллере строятся по одному принципу. Отличие только в числе нейронов в выходном слое. Базовая НС (табл. 2, п. 1) представлена вероятностной сетью, дополненной линейной сетью (табл. 2, п. 2). НС точной оценки параметров (табл. 2, п. 3) обеспечивает заданную точность.

Таблица 2

Назначение устройств и выполняемые задачи

Номер	Функциональное устройство	Решаемая задача
1		Нейронная сеть первого уровня NS1 (Вероятностная сеть) $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{1i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{2i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{3i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{4i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{5i}$
2		Линейная нейронная сеть $k_1 \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_2 \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_3 \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_4 \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_5 \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$
3		Нейронная сеть точной оценки (Вероятностная сеть) $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{1i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{2i}$ $x_i = [x_{i,t}, x_{i,t-1}, \dots, x_{i,t-p}] \rightarrow k_{3i}$
4		Линейная нейронная сеть $k_{1i} \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_{2i} \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$ $k_{3i} \rightarrow y_j = [y_{j,t}, y_{j,t-1}, \dots, y_{j,t-p}]$
5		Блок анализа if in1 =d1 then out 1 else if in1 =d2 then out 2 else
6		Коммутатор In1 Out1(2...5) In2 $k_i = k_{1i} \dots k_{5i}$

Особенность такого решения связана с тем, что кроме номера кластера нам важно получить конкретное значение исследуемого параметра. Конкретное значение параметра используется для управле-

ния передачей данных между НС точной оценки параметров. Так же передается исследуемый сигнал на входы нейронных блоков точной с использованием основ коммутаторов.

Коммутаторы, часть из которых (табл. 2, п. 5) выполняет анализ на основе логических уравнений и передает полученный параметр, а часть (табл. 2, п. 6), передает сам сигнал, выполняя функции демультиплексора.

Результатом работы нейроконтроллера является вывод сообщения о параметре, содержащем конкретные величины коэффициента усиления и постоянной времени в контролируемом блоке. Если в ЭМС системе имеется техническая возможность изменять параметры, то процесс автоматически введет коррекцию, возвращая истинное значение параметра в соответствующем устройстве.

В эксперименте использовались коэффициенты усиления в диапазоне 1,5–3 (15–25) и постоянные времени 0,01–0,05 (0,01–0,08). Критические значения выводились сообщением об ошибках $K > K_{к1}$, $K < K_{к2}$, а значения коэффициента усиления и постоянной времени в числовом виде.

Заключение

Рассмотренный в статье метод показал удовлетворительные результаты и может быть использован для диагностики электро-механических приводов станков и роботов. Привод не требует конструктивных изменений. Достаточно подключить измерительное устройство к исследуемому объекту и загрузить соответствующий программный модуль (обучение или диагностирующий процесс). Реализовать метод лучше всего в виде двух программных модулей,

один из которых решает задачу сбора данных для обучения нейроконтроллера и его обучение, а второй непосредственно выполняет процесс анализа параметров регуляторов в динамических режимах. Наиболее трудоемкой задачей является сбор данных и обучение нейронных сетей. Рассмотренный метод применим к решению любой задачи, связанной с контролем параметров в электроприводе.

Список литературы

1. Тимофеев А.В., Косовская Т.М. Нейросетевые методы логического описания и распознавания сложных образов // Труды СПИИРАН. 2013. Вып. 4 (27). С. 144–153.
2. Янковская А.Е., Гедике А.И. Интеллектуальная подсистема построения отказоустойчивых безусловных диагностических тестов и принятия решений на их основе // XIV национальная конференция по искусственному интеллекту с международным участием КИИ-2014 (Казань, 24–27 октября 2014 г.). Труды конференции. В 3-х т. Казань: Изд-во РИЦ «Школа», 2014. С. 93–101.
3. Battyshin I.Z. Theoretical bases of the methods of construction of association measures in intelligent data analysis // XIV национальная конференция по искусственному интеллекту с международным участием КИИ-2014 (Казань, 24–27 октября 2014 г.). Труды конференции. В 3-х т. Казань: Изд-во РИЦ «Школа», 2014. С. 243–251.
4. Рассел С., Норвиг П. Искусственный интеллект: современный подход / Пер. с англ. и ред. К.А. Птицына. 2-е изд. М.: Вильямс, 2017. 1407 с: ил., табл.
5. Сапрыкин О.Н. Интеллектуальный анализ данных: учебное пособие. Самара: Издательство Самарского университета, 2020. 79 с.
6. Веселов О.В., Сабуров П.С., Перепелкин В.М. Виртуальная модель привода постоянного тока для задач диагностики // Известия высших учебных заведений. Электро-механика. 2018. Т. 61. № 6. С. 51–60.