

УДК 62-83:621.313.39

ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ ЭКСПЛУАТАЦИИ ЭЛЕКТРОМЕХАНИЧЕСКОГО ПРИВОДА В МАШИНОСТРОИТЕЛЬНОМ ПРОИЗВОДСТВЕ НА ОСНОВЕ ДИАГНОСТИКИ

А.Ю. Волков, С.Г. Светушенко

Показаны пути повышения эффективности функционирования электромеханического привода (ЭМП), связанные с обеспечением работоспособности по заданным эксплуатационным характеристикам на всем жизненном цикле работы оборудования на основе использования алгоритмов нейродиагностирования и структуры нейродиагностических модулей, работающих параллельно оборудованию в режиме реального времени. Для диагностики ЭМП составляется нейронная сеть, позволяющая делать выводы о текущем состоянии. Выполнена научно-квалификационная работа, в которой содержится решение актуальной задачи повышения эффективности эксплуатации электромеханического привода машиностроительного производства, основанное на создании нейродиагностических модулей, обеспечивающих в реальном времени оценку состояния с заданной точностью и быстротой действия.

Ключевые слова: электромеханический привод; нейросети; нейронный модуль; нейродиагностика.

ДИАГНОСТИКАНЫН НЕГИЗИНДЕ МАШИНА КУРУУЧУ ӨНДҮРҮШТӨ ЭЛЕКТРОМЕХАНИКАЛЫК ПРИВОДДУ ЭКСПЛУАТАЦИЯЛООНУН НАТЫЙЖАЛУУЛУГУН ЖОГОРУЛАТУУ

А.Ю. Волков, С.Г. Светушенко

Бул макалада электромеханикалык приводдун иштөө натыйжалуулугун жогорулатуу жолдору көрсөтүлгөн, ал реалдуу убакыт режиминде жабдуу менен бир мезгилде иштеген нейродиагностикалоочу алгоритмдерди жана нейродиагностикалык модулдарды пайдалануунун негизинде жабдуунун иштөө циклиндеги эксплуатациялык мүнөздөмөлөрү боюнча иш жөндөмдүүлүгүн камсыз кылуу менен байланышкан. Электромеханикалык приводду диагностикалоо үчүн анын учурдагы абалы тууралуу жыйынтык чыгарууга мүмкүндүк берүүчү нейрон тармагы түзүлөт. Бул аткарылган илимий-квалификациялык эмгекте реалдуу убакытта абалына так жана тез арада баа берүүнү камсыз кылуучу, нейродиагностикалык модулдарды түзүүгө негизделген, машина куруучу өндүрүштө электромеханикалык приводду эксплуатациялоонун натыйжалуулугун жогорулатуу боюнча актуалдуу маселе чечилген.

Түйүндүү сөздөр: электромеханикалык привод; нейрон тармактары; нейрон модулу; нейродиагностика.

INCREASING THE EFFICIENCY OF OPERATION OF ELECTROMECHANICAL DRIVE OF MACHINE-BUILDING PRODUCTION ON THE BASIS OF DIAGNOSTICS

A. Yu. Volkov, S. G. Svetushenko

The ways of increase of efficiency of functioning of EMF related to the provision of health according to specified performance throughout the life cycle of the equipment based on the use of algorithms neurodiagnostics and structure neurodiagnostics modules operating in parallel, in real-time. For diagnostics of the electric drive the neural network allowing to draw conclusions about the current state is made. The scientific and qualification work is carried out, which contains the solution of the actual problem of increasing the efficiency of operation of the Electromechanical drive of machine-building production based on the creation of neurodiagnostic modules providing real-time assessment of the state with a given accuracy and speed.

Keywords: electromechanical drive; neural networks; neural module; neurodiagnostics.

Введение. Обеспечение работоспособности электромеханического привода так же, как и всех устройств промышленных механизмов автоматизированного производства, в значительной степени определяет качественные характеристики выпускаемой продукции. Так, например, изменение скоростей приводов подач приводит к нарушению геометрии изделий. Изменение постоянной времени в переходных процессах вносит динамическую ошибку, что сказывается на точности обработки конечного изделия. Практически любое отклонение параметров привода от паспортных значений влияет на качество обработки изделий. Обеспечить стабильность параметров привода позволят специализированные средства диагностирования и эффективные алгоритмы выполнения диагностических операций.

Технические системы диагностирования принято делить на две категории. В первой диагностирование осуществляется в текущем времени путем сравнения поведения переменных реального объекта и его математической модели при наличии заранее известного детерминированного соответствия между ними. Во второй используются элементы искусственного интеллекта, среди которых наиболее развиты системы распознавания форм, экспертные системы и сеть искусственных нейронов.

Во второй категории систем диагностирования основной задачей является составление каталога отказов-симптомов универсальных аппроксиматоров (сети нейронов). Следует отметить, что искусственная нейронная сеть (ИНС) обладает характеристиками, позволяющими автономно решать проблемы классификации переменных объекта и их форм, а также самообучения алгоритмам диагностирования, исходя из опыта отказов. ИНС позволяет разработать непараметрическую модель, которая может воспроизвести любое исправное и неисправное состояние электропривода и, более того, аппроксимировать свою идентификацию на другие примеры, которые не были изучены. Такая модель способна запоминать примеры событий, распределяя на их основании веса соединений структуры, вплоть до устранения нейронов или соединений, которые не влияют на запоминание примеров.

Архитектура системы диагностирования неисправностей электромеханических устройств

представляет собой две подсистемы: подсистему приема и обработки информации и подсистему интерпретации полученной информации о состоянии объекта диагностирования. Первая осуществляет прием данных по состоянию объекта и их последующую обработку (распределение данных, оценку переменных и их отображение). Вторая подсистема производит распознавание с помощью ИНС неисправностей электромеханической системы и дает рекомендации по реализации дальнейших ее действий. Применение при диагностировании большого числа контролируемых переменных электропривода (например, напряжений и токов обмоток статора электродвигателя, частоты вращения) позволяет увеличить достоверность диагностирования и сделать ее более эффективной.

Для реализации модуля ИНС предварительно определяются размеры нейронной сети, т. е. число ее входов и выходов. Затем архитектура сети формируется, исходя из алгоритма обучения и минимизации среднеквадратической ошибки результатов диагностирования.

Прежде чем встроить блок ИНС в подсистему интерпретации информации, изучаются три нейронных сети с входами разной архитектуры. Входы трех сетей не одного и того же размера, а, следовательно, и их структуры, выбранные после фазы обучения, будут отличаться (иметь разное число внутренних слоев и число нейронов в этих слоях).

Для создания на базе ИНС модели, описывающей исправное и неисправное состояние электромеханической системы, необходима такая база данных, в которой содержалась бы достаточная информация о возможных дефектах, возникающих в различных режимах работы электропривода. С этой целью были смоделированы возможные неисправности электропривода при различных режимах работы двигателя и для каждого состояния оценивались изменения текущих значений трёх выбранных ранее переменных в течение периода изменения тока статора. В итоге база данных каждой переменной составила 3000 разных значений (векторов), характеризующих возможные режимы работы электропривода. Это число, соответствующее числу результатов, и необходимо сообщить нейронной сети.

Анализ опубликованных работ по теме показал, что в литературе слабо освещены вопросы

Таблица 1 – Распознавание кривых при различной разрядности АЦП

	10 разрядов		9 разрядов		8 разрядов		7 разрядов	
	Сост. 1	Сост. 2	Сост. 1	Сост. 2	Сост. 1	Сост. 2	Сост. 1	Сост. 2
Кривая 1	84	17	86	15	86	15	86	15
Кривая 2	26	74	22	78	23	77	23	77
Кривая 3	72	29	72	29	68	33	64	37

построения диагностических систем, ориентированных на диагностику с использованием нейронных сетей. Полностью отсутствуют сведения о методиках построения программных средств. Также нет целостного представления о проблеме диагностики электромеханических систем (ЭМС), позволяющей использовать накопленный опыт для решения широкого спектра задач, связанных с качеством работы ЭМС [1–4].

Обработка полученной от ЭМС информации предполагает процедуру ее распознавания для соотнесения к определенному состоянию. Традиционно большинство систем распознавания для решения конкретной задачи используют какой-либо один метод классификации. Однако ни один из них не является универсальным, и разные методы основываются на разных подходах. Вследствие этого методы, обеспечивающие одинаковую или близкую надежность классификации для всей обучающей и/или контрольной выборки в целом, для отдельных экземпляров могут давать разные результаты.

Естественно, что подобные системы, построенные на основе одного классификатора, не будут удовлетворять высоким требованиям надежности, предъявляемым во многих областях промышленности.

Кроме того, построение эффективной модели объекта возможно только при наличии оптимального набора признаков, причем, для каждой модели, в общем случае, оптимальные наборы будут различными и одного только предварительного задания набора признаков будет недостаточно. Также необходимо учитывать, что классификаторы содержат достаточное количество параметров, которые необходимо настроить (для ИНС – это количество слоев, количество нейронов в слое, структура связей, вид функции активации, параметры алгоритма обучения).

Для решения задач диагностики, как, впрочем, и для решения других задач можно пойти

двумя путями: либо разработать новую сеть, и тогда необходимо будет руководствоваться тем, что возможности сети возрастают с увеличением числа нейронов, плотности связей между ними и числом выделенных слоев; введение обратных связей наряду с увеличением возможностей сети ставит вопрос о динамической устойчивости сети; сложность алгоритмов функционирования сети (в том числе, например, введение нескольких типов синапсов – возбуждающих, тормозящих и др.) или воспользоваться известными решениями и подобрать необходимую сеть, и в этом случае нахождение оптимального варианта будет основано на интуитивном подборе, что не менее сложно [5].

В нашем случае воспользуемся вторым подходом. При распознавании состояния ЭМС из известного набора выберем такую топологию сети, которая обеспечит минимум одних и максимум других параметров. Исследование и тестирование различных архитектур нейронных сетей выполним на модели ЭМС с приводом постоянного тока. При этом необходимо учесть, что в системах диагностирования для обработки информации используется микропроцессорная техника, которая предполагает использование преобразователей аналоговых сигналов в цифровую форму (код), а в процессе диагностирования для систем реального времени также важны быстродействие и точность, что, в свою очередь, накладывает дополнительные условия, связанные с характеристиками используемой сети, структурой ее построения, точностью обучения, временем обучения и т. д.

В результате исследований было установлено, что наиболее подходящими являются три типа: двухслойный персептрон, сеть встречного распространения и вероятностная сеть.

В процессе исследования на входы нейросети подавался цифровой двоичный код с разным числом разрядов. Результаты представлены в таблице 1.

Процент распознавания кривой, подаваемой на вход нейронной сети, в зависимости от количества разрядов, подаваемых на вход нейронной сети, представлен в таблице 2.

Таблица 2 – Процент распознавания кривой при различной разрядности

	Кривая 1	Кривая 2	Кривая 3
10 разрядов	84	74	72
9 разрядов	86	78	72
8 разрядов	86	77	68
7 разрядов	86	77	64

Наилучшие результаты получили при подаче на вход девяти разрядов.

С использованием потенциала нейросетей был построен алгоритм диагностики ЭМС, который позволяет достаточно точно определять вид и параметры сигнала в каждой контрольной точке объекта диагностики, и классифицировать его. На основании этой классификации можно определить как причину, так и степень неисправности.

В качестве примера разработаем алгоритм диагностики регулятора скорости, как одного из основных элементов привода. При этом алгоритм диагностики любого другого элемента будет отличаться лишь в количестве и типе определяющих параметров сигнала, снимаемого с элемента, необходимых для установления причин нарушения нормальной работы элемента. К таким параметрам можно отнести: коэффициент усиления, постоянную времени, коэффициент демпфирования, период, начальную фазу, скважность и др.

В качестве регуляторов скорости применяют ПИ-регуляторы. Данный вид регуляторов обеспечивает нулевую статическую ошибку регулирования. Они достаточно просты в настройке, т. к. настраиваются только два параметра: коэффициент усиления K (пропорциональная составляющая) и постоянная времени T (интегральная составляющая) (таблица 3). В таких регуляторах имеется возможность оптимизации $K/T \rightarrow \max$, что обеспечивает управление с минимально возможной среднеквадратичной ошибкой регулирования. Этот тип регуляторов обладает малой чувствительностью к шумам в канале измерения (в отличие от ПД- и ПИД-регуляторов).

Рассмотрим возможные неисправности ПИ-регулятора и определим последовательность их диагностирования.

Весь алгоритм разбиваем на три этапа.

1. Выбор типа и обучение нейросети для решения поставленной задачи.
2. Оценка сигнала с объекта диагностики нейросетями, определение постоянной времени и коэффициента передачи.
3. Определение причины неисправности по известным K и T .

Рассмотрим более подробно каждый этап.

Этап 1. Выбор типа и обучение нейросети для решения поставленной задачи. Моделирование сетей проводилось в пакете NNToll среды Matlab.

1.1. В пакете Neural Network Toolbox выбираем несколько сетей таким образом, чтобы нейросеть поддерживала распознавание трех и пяти входных векторов.

Таблица 3 – Изменение параметров регулятора

		Значение коэффициента усиления сигнала K				
		$K \uparrow \uparrow$	$K \uparrow$	K	$K \downarrow$	$K \downarrow \downarrow$
Значение постоянной времени сигнала T	$T \uparrow \uparrow$	$C1 \uparrow, R1 \downarrow \downarrow, R2 \uparrow$	$C1 \uparrow, R2 \uparrow$	$C1 \uparrow \uparrow$	$C1 \uparrow, R1 \uparrow, R2 \uparrow$	$C1 \uparrow, R1 \uparrow \uparrow, R2 \uparrow$
	$T \uparrow$	$R1 \downarrow \downarrow, R2 \uparrow$	$R2 \uparrow$	$C1 \uparrow$	$R1 \downarrow, R2 \uparrow$	$R1 \uparrow \uparrow, R2 \uparrow$
	T	$R1 \downarrow \downarrow$	$R1 \downarrow$	-	$R1 \uparrow$	$R1 \uparrow \uparrow$
	$T \downarrow$	$R1 \downarrow \downarrow, R2 \downarrow$	$R1 \downarrow, R2 \downarrow$	$C1 \downarrow$	$R2 \downarrow$	$R1 \uparrow, R2 \downarrow$
	$T \downarrow \downarrow$	$C1 \downarrow, R1 \downarrow \downarrow$	$C1 \downarrow, R1 \downarrow \downarrow, R2 \downarrow$	$C1 \downarrow \downarrow$	$C1 \downarrow, R2 \downarrow$	$C1 \downarrow, R1 \uparrow, R2 \downarrow$

Обозначения: $\downarrow \downarrow$ – значительное снижение параметра, \downarrow – незначительное снижение параметра, \uparrow – незначительное увеличение параметра, $\uparrow \uparrow$ – значительное увеличение параметра регулятора.

1.2. Снимаем с модели объекта диагностики сигналы таким образом, чтобы коэффициент передачи имел пять фиксированных значений, а постоянная времени оставалась неизменной. Данные сигналы собираем в один входной обучающий вектор, который будет представлять собой матрицу из пяти столбцов и N строк. Количество строк определяется временем моделирования при снятии сигналов с объекта диагностики.

1.3. Обучение нейросети. Обучение заключается в подаче на вход нейросети вектора-матрицы сигналов и вектора-цели.

1.4. Тестирование нейросети. Данный процесс заключается в соответствии выходного вектора нейросети вектору-цели при подаче на вход одного или всех сигналов обучающего вектора.

1.5. Если соответствие между выходным вектором и вектором-целью 100 %, то переходим на пункт 1.7, иначе переходим на пункт 1.6.

1.6. Пробуем подобрать новые параметры обучения для нейросети и пройти пункты 1.3 и 1.4 (1.8), (1.11) еще раз. При этом не следует изменять параметры бесконечно – изменив параметры несколько десятков раз и не получив положительного результата в пункте 1.4, следует выбрать новый тип нейросети и начать алгоритм сначала.

1.7. Снимаем с модели сигналы при таких параметрах объекта диагностики, чтобы постоянная времени оставалась неизменной, а коэффициент передачи имел произвольное значение.

1.8. Тестирование нейросети сигналами при произвольном коэффициенте передачи. Каждый обучающий сигнал из пункта 1.2 создает вблизи себя зону, при этом любые сигналы, попавшие в данную зону, распознаются как обучающий сигнал. Поэтому подбираем K так, чтобы знать заранее, какой зоне он принадлежит на самом деле.

1.9. Если сигналы с произвольными коэффициентами передачи попадают в соответствующие зоны 100 %, то переходим на пункт 1.10, иначе переходим на пункт 1.6.

1.10. Зададимся несколькими значениями коэффициента передачи в каждой из зон и снимем с объекта диагностики сигналы при различных значениях постоянной времени.

1.11. Тестирование нейросети сигналами из пункта 1.10. На данном этапе необходимо сравнить, насколько сдвинулись зоны распознавания коэффициента передачи относительно эталонных зон при различных значениях постоянной времени.

1.12. Если дефект зон распознавания не превышает заданный, то переходим на пункт 1.13, иначе переходим на пункт 1.6.

1.13. Снимаем с модели объекта диагностики сигналы таким образом, чтобы постоянная времени имела пять фиксированных значений, а коэффициент передачи оставался не-

изменным. Данные сигналы собираем в один входной обучающий вектор, однако первым должен стоять сигнал с наименьшей постоянной времени, а последним – сигнал с наибольшей постоянной времени. Изменение порядка сигналов в обучающем векторе резко снижает качество распознавания.

1.14. Обучение нейросети с использованием нового обучающего вектора.

1.15. Тестирование нейросети, т. е. нахождение соответствия выходного вектора нейросети вектору-цели при подаче на вход одного или всех сигналов обучающего вектора из пункта 1.13.

1.16. Если соответствие между выходным вектором и вектором-целью 100 %, то переходим на пункт 1.18, иначе переходим на пункт 1.17.

1.17. Пробуем подобрать новые параметры обучения для нейросети применительно к новому обучающему вектору и пройти пункты 1.14 и 1.15 еще раз. Если подобрать параметры не получилось, то необходимо выбрать другой тип нейросети и начать алгоритм сначала.

1.18. Снимаем с модели сигналы при таких параметрах объекта диагностики, чтобы коэффициент передачи оставался неизменным, а постоянная времени имела произвольное значение. Каждый обучающий сигнал из пункта 1.13 создает вблизи себя зону, при этом любые сигналы, попавшие в данную зону, распознаются как обучающий сигнал. Поэтому подбираем T так, чтобы знать заранее, какой зоне он принадлежит на самом деле.

1.19. Тестирование нейросети сигналами при произвольной постоянной времени.

1.20. Если сигналы с произвольными постоянными времени попадают в соответствующие зоны 100 %, то переходим на пункт 1.21, иначе переходим на пункт 1.17.

1.21. Зададимся несколькими значениями постоянной времени в каждой из зон и снимем с объекта диагностики сигналы при различных значениях коэффициента передачи.

1.22. Тестирование нейросети сигналами из пункта 1.21. Если сигналы попадают в соответствующие зоны 100 %, то переходим на пункт 1.23, иначе переходим на пункт 1.17.

1.23. Делаем вывод об использовании данного типа нейросети и для оценки K , и для оценки T .

1.24. Нейросети данного типа обучаем следующим образом: одни из них способны

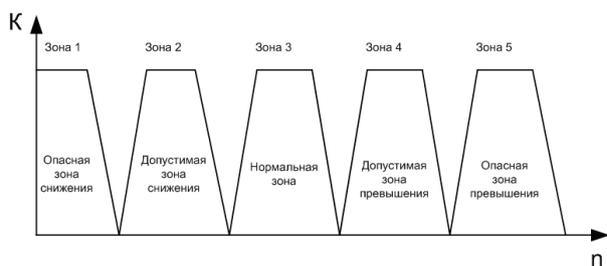


Рисунок 1 – Зоны изменения коэффициента усиления

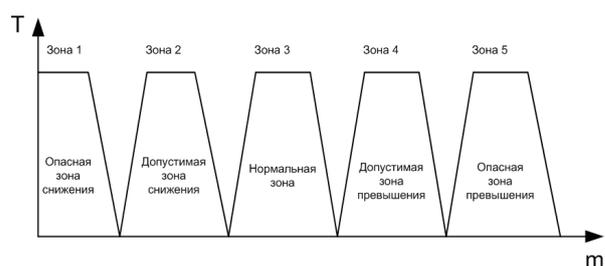


Рисунок 2 – Зоны изменения постоянной времени

распознавать сигналы и оценивать коэффициент передачи, используя вектор-матрицу из пункта 1.2, а другие – используя вектор-матрицу из пункта 1.13. При этом 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 .

Этап 2. Оценка сигнала с объекта диагностики нейросетями, определение постоянной времени и коэффициента передачи.

2.1. Снимаем сигнал с объекта диагностики. Кривая сигнала разбита на N точек, причем каждая точка подается на вход нейросетей одновременно.

2.2. Оценка сигнала нейросетью по коэффициенту передачи.

Данный этап является основополагающим для дальнейшей диагностики, т.к. на нем происходит первичная оценка K , т.е. отнесение коэффициента передачи к определенной области. Таких областей пять (рисунок 1).

Каждой зоне соответствует обучающая кривая с фиксированным коэффициентом передачи.

2.3. Если кривая принадлежит зоне 1, то переходим на пункт 2.7, иначе переходим на пункт 2.4.

2.4. Если кривая принадлежит зоне 2, то переходим на пункт 2.7, иначе переходим на пункт 2.5.

2.5. Если кривая принадлежит зоне 3, то переходим на пункт 2.7, иначе переходим на пункт 2.6.

2.6. Если кривая принадлежит зоне 4, то переходим на пункт 2.7, иначе кривая принадлежит зоне 5, переходим на пункт 2.7.

2.7. Выбираем нейросеть оценки постоянной времени под найденную зону коэффициента передачи.

2.8. Оценка сигнала нейросетью по постоянной времени в определенной, фиксированной зоне коэффициента передачи. Данный этап является заключительным, т.к. на нем происходит оценка T , т.е. отнесение постоянной времени к определенной области. Таких областей пять (рисунок 2).

Каждой зоне K соответствует нейросеть оценки T , причем обучающие кривые снимаются при коэффициенте передачи, принадлежащем данной зоне.

2.9. Анализ найденной зоны постоянной времени и зоны коэффициента передачи. Данный этап необходим, чтобы определить наличие или отсутствие дефектов. Так, если параметры сигнала с объекта диагностики находятся в нормальной зоне, то делаем вывод, что регулятор исправен, при этом, если хотя бы один из параметров вышел из нормальной зоны, то это говорит о наличии дефектов.

Этап 3. Определение причины неисправности по известным K и T .

На данном этапе зоны коэффициента передачи и постоянной времени должны быть однозначно определены, поэтому, используя данные таблицы 3, определяем причину и степень дефекта и выводим на экран причин дефектов.

Структура нейродиагностического модуля строится на основании приведенного алгоритма и изменений, внесенных в него. Структура модуля представлена на рисунке 3.

Рассмотрим более подробно каждый блок.

Блок оценки коэффициента усиления представляет собой совокупность двух нейросетей: нейросети для оценки коэффициента усиления и преобразующей нейросети.

Блок точной оценки коэффициента усиления в зоне 2, БТК3, БТК4. Основная функция данных блоков заключается в том, чтобы оценить

коэффициент усиления с такой точностью, чтобы ее хватило для оценки постоянной времени сигнала с регулятора. Как показала практика, достаточной и необходимой точностью оценки K является 0,01.

Блок анализа K в зоне 2. Основной функцией данного блока является обработка информации с нейросетей точной оценки и передача мультиплексу оценки постоянной времени кода о найденном коэффициенте усиления или передача кода на мультиплексор вспомогательных нейросетей оценки коэффициента передачи о необходимости доопределить K .

Мультиплексор вспомогательных нейросетей оценки коэффициента передачи. Основная функция данного блока – передача сигнала с регулятора на вход одной из вспомогательных нейросетей оценки K по сигналу от блока оценки K в зоне 2.

Вспомогательные нейросети. Данные нейросети необходимы, чтобы с более высокой точностью оценить K .

Блок анализа результатов вспомогательных нейросетей. Основной функцией данного блока является обработка информации с вспомогательных нейросетей и передача мультиплексу оценки постоянной времени кода о найденном коэффициенте усиления.

Мультиплексор оценки коэффициента усиления. Основная функция блока заключается в передаче сигнала с регулятора на вход одного из трех блоков точной оценки K .

Коммутатор дефектов объекта диагностики. Основная функция данного блока заключается в том, чтобы по сигналу, приходящему с сумматора или от мультиплексора оценки K , активировать тот информационный экран, в котором содержится сообщение о виде и степени дефекта объекта диагностики.

На рисунке 4 показана экспериментальная установка, с помощью которой можно производить оценку состояния, выполненную каким-либо образом с возможностью формирования единственного вывода, полученного с привлечением алгоритмов искусственного интеллекта, принять решение и, если система полностью автоматическая, реализовать его. В противном случае следует вывести сообщение о надлежащих действиях для устранения дефекта в диагностируемой системе.

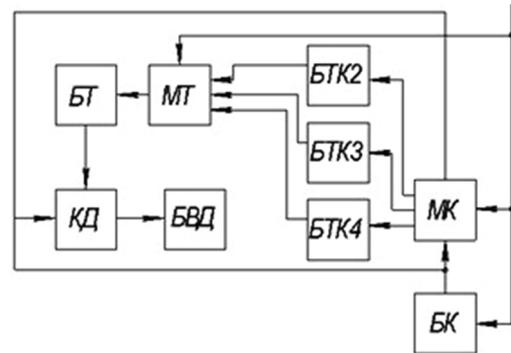


Рисунок 3 – Структура нейродиагностического модуля:

- БК – блок оценки коэффициента усиления;
- БТ – блок оценки постоянной времени;
- БТК2 – блок точной оценки коэффициента усиления в зоне 2; БТК3 – блок точной оценки коэффициента усиления в зоне 3;
- БТК4 – блок точной оценки коэффициента усиления в зоне 4;
- КД – коммутатор дефектов;
- МК – мультиплексор оценки коэффициента усиления;
- МТ – мультиплексор оценки постоянной времени.

Система диагностирования включает в себя четыре основных подсистемы: программное обеспечение (пакет Matlab), измерительную плату NI6221, модуль сопряжения BNC2120 и собственно объект диагностирования, в качестве которого рассматривается привод постоянного тока. Особенность системы заключается в том, что управление работой привода, процессом измерений и обработкой информации осуществляется под управлением пакета Simulink.

Основные результаты и выводы

Выполнена научно-квалификационная работа, в которой содержится решение актуальной задачи повышения эффективности эксплуатации электромеханического привода машиностроительного производства, основанное на создании нейродиагностических модулей, обеспечивающих в реальном времени оценку состояния с заданной точностью и быстродействием.

Применение при диагностировании большого числа контролируемых переменных электропривода (например, напряжений и токов обмоток статора электродвигателя, частоты вращения) позволяет увеличить достоверность

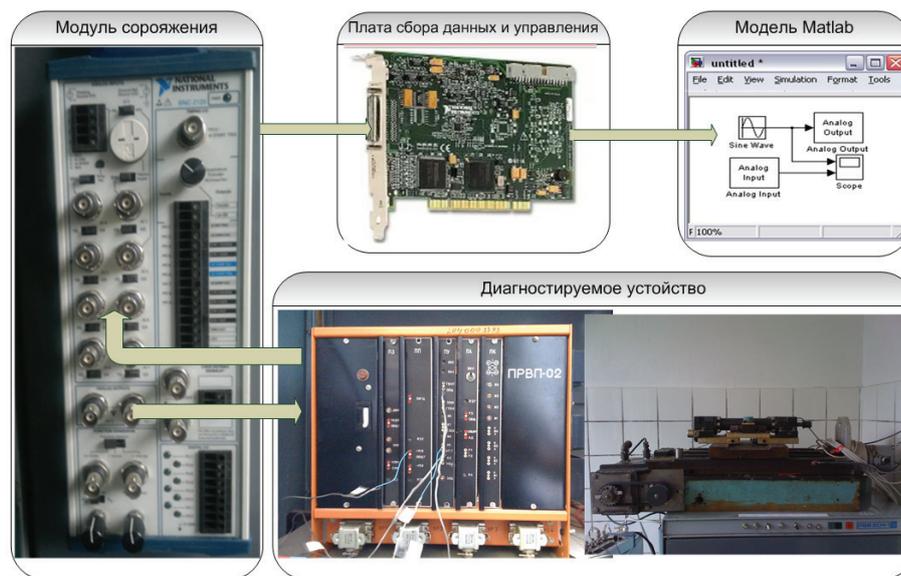


Рисунок 4 – Экспериментальная установка. Модуль сопряжения. Плата сбора данных и управления. Диагностическое устройство

диагностирования и сделать его более эффективным с использованием вероятностных нейронных сетей.

Для реализации модуля ИНС предварительно определяются размеры нейронной сети, т. е. число ее входов и выходов. Затем архитектура сети формируется, исходя из алгоритма обучения и минимизации среднеквадратической ошибки результатов диагностирования.

Разработанные нейродиагностические модули могут быть использованы для диагностики любых электромеханических систем с минимальными изменениями, характеризующимися свойствами объекта диагностики. Алгоритм создания нейронного модуля позволяет сформировать любой нейродиагностический модуль под реализуемую задачу с минимальными затратами.

Результаты исследований могут быть использованы в различных отраслях промышленности, где реализуются технологические процессы повышенной точности, а также в учебном процессе по дисциплине “Методы искусственного интеллекта в мехатронике и робототехнике” при подготовке магистров по направлениям “Машиностроение”, “Конструкторско-технологическое обеспечение машиностроительных производств” и “Мехатроника и робототехника”, а также

в системе повышения квалификации по этим направлениям.

Литература

1. Никулин Н.А. Основы теории автоматического управления. Частотные методы анализа и синтеза систем / Н.А. Никулин. СПб.: БХВ-Петербург, 2012. 601 с.
2. Чернышев А.Ю. Электропривод переменного тока: учебн. пособие для студентов вузов / А.Ю. Чернышев, Ю.Н. Дементьев, И.А. Чернышев. Томск: Изд-во Томск. политехн. ун-та, 2011. 213 с.
3. Шетат Б. Использование искусственных нейронных сетей для диагностики неисправности асинхронного электропривода в режиме реального времени / Б. Шетат, Дж. Ходжа // Электротехника. 2003. № 12. С. 16–20.
4. Рудакова Т.А. Сравнение и выбор нейросетевых моделей на основе метода анализа иерархий / Т.А. Рудакова, Н.И. Червяков, В.Ф. Лубенцов // Приборы и системы управления, контроль, диагностика. 2008. № 5. С. 1–5.
5. Веселов А.О. Косвенное измерение переменных состояния для диагностирования электродвигателей / О.В. Веселов, Е.Ю. Ермоленко, А.О. Веселов // Известия вузов. Электромеханика. 2008. № 2. С. 24–27.