

Превентивное прогнозирование технического состояния электроприводов транспортных систем методом искусственных нейронных сетей

Крюков О.В.

ООО «ТСН-электро»
Нижний Новгород, Россия
o.v.kryukov@mail.ru

Саушев А.В., Тырва В.О., Антоненко С.И.

кафедра ЭПиЭОБУ
ФГБОУ ВО «ГУМРФ имени адмирала С.О. Макарова»
Санкт-Петербург, Россия
saushev@bk.ru

Аннотация — Рассмотрены вопросы проектирования эффективных и достоверных систем оперативной диагностики электродвигателей транспортных систем на примере электроприводных компрессорных станций. Представлена статистика выхода из строя наиболее ответственных установок газотранспортных систем – электроприводных газоперекачивающих агрегатов. Разработана методология и архитектура искусственных нейронных сетей для получения прогнозных моделей электрических машин большой мощности. Приведены примеры нейро-нечеткого прогнозирования технического состояния и ресурса статорных обмоток синхронных машин. Получены тесты селекционированных сетей, нечеткая модель Бокса-Дженкинса, модели метода анализа динамики спектральных составляющих, прогнозирование величин тока и температур статора. Сопоставительные результаты анализа ожидаемых состояний электрических машин магистрального транспорта газа, исходя из учета различных эксплуатационных факторов работы электроприводных газоперекачивающих агрегатов, позволили выработать рекомендации по применению метода искусственных нейронных сетей применительно к транспортным электроприводным системам.

Ключевые слова транспортные электроприводные системы, газоперекачивающий агрегат, электродвигатель, искусственные нейронные сети, тесты селекционированных сетей, модели прогнозирования величин тока и температур статора электрической машины.

I. ВВЕДЕНИЕ

В настоящее время особую актуальность приобретают вопросы разработки достоверных и оперативных систем мониторинга технического состояния автоматизированных электроприводов ответственного назначения. Это в полной мере относится к транспортным системам, включая, например, судовые электроприводы, электроприводы гидротехнических сооружений, электроприводы технологических установок компрессорных станций магистральных газопроводов, которые относятся к опасным и ответственным транспортным объектам [1-5]. Отличительной особенностью современных электроприводных транспортных систем ответственного назначения (ЭТСОН) как объектов диагностирования

является то, что они представляют собой сложные и пространственно-распределенные технические системы с разнородными элементами. Для диагностирования электроприводов транспортных систем разработано достаточно большое количество методов оценки и прогнозирования их технического состояния [8-12].

Рассмотрим в качестве примера электроприводной газоперекачивающий агрегат (ЭПА) [4-7], внешний вид которого представлен на рис. 1. Статистические данные по более чем 100 случаям отказов ЭПА на шести компрессорных станциях ПАО «Газпром» показали, что наиболее тяжелым по затратам и времени восстановления является выход из строя приводного электродвигателя и, особенно, пробой изоляции статора [13-17].



Рис. 1. Электроприводной газоперекачивающий агрегат 4 МВт

Для 60 электродвигателей типа СТД-12500-2 и СДГ-12500 за период эксплуатации выполнены измерения основных эксплуатационных факторов их работы в различных режимах работы в условиях действующих компрессорных цехов и выявлены наиболее характерные виды повреждений. Проведен комплексный анализ и определены 4 группы эксплуатационных факторов [14-18], влияющих на ресурс электродвигателей ЭПА. К ним относятся: нагрев изоляции обмоток статора, изменения параметров питающего напряжения, электродинамические нагрузки в стержнях и частичные разряды в изоляции

обмоток. Аналогичные и близкие к ним результаты получены при анализе электродвигателей других транспортных систем [].

II. Методология использования теории нейронных сетей для оценки технического состояния ЭТСОН

мониторинга и прогнозирования технического состояния ЭТСОН, как и других электроприводных систем (рис. 2) является хорошо разработанный и апробированный в некоторых технических системах математический аппарат автоматизированной настройки параметров диагностических алгоритмов на основе *искусственных нейронных сетей* (ИНС), объединенных в систему принятия решений (СПР) по идентификации различных дефектов [19-22].

1. По структурной сложности	2. По способу получения прогнозной информации	3. По степени формализации
1.1. Простые методы, неразложимые на еще более простые методы	2.1. Формализованные методы базируются на имеющемся информационном материале (априорной информации) об объекте прогнозирования и предстории его развития	3.1. Методы экстраполяции, при достоверной априорной информации о процессе, достаточная для идентификации типа его прогностической модели
1.2. Комплексные методы состоят из взаимосвязанной совокупности нескольких простых методов	2.2. Экспертные методы основаны на оценке мнения множества экспертов по развитию процесса, развитие которого не поддается математической формализации.	3.2. Ассоциативные методы или нейронные сети обоснованы, когда прогнозируемый процесс является функцией только входных параметров
		3.3. Математические методы (корреляционный анализ, временные ряды)

Рис. 2. Классификация методов прогнозирования состояния ЭТСОН

Особенностью ИНС является то, что она обладает характеристиками, позволяющими автономно решать проблемы классификации переменных исследуемого объекта и их форм, а также самообучения алгоритмам прогнозирования, исходя из опытных данных по отказам элементов ЭТСОН. ИНС позволяет синтезировать непараметрическую модель, на основе которой можно воспроизвести практически любое техническое состояние ЭТСОН и решить задачу идентификации.

Такая модель способна запоминать отдельные события, распределяя на их основании веса связей структуры, вплоть до устранения нейронов или соединений, которые не влияют на запоминание этих событий [].

Рассмотрим архитектуру встроенных систем мониторинга и прогнозирования (ВСМП) технического состояния ЭТСОН с использованием ИНС на примере ЭГПА (рис. 3). Она представляет собой 2 подсистемы:

подсистему приема и обработки информации, которая соответствует ВСМП работы электродвигателей СТД-12500-2 ЭГПА с приемом данных по техническому состоянию приводного высоковольтного синхронного двигателя (ПВСД) и их последующую обработку (распределение данных и оценку переменных);

подсистему интерпретации полученной информации о техническом состоянии с использованием алгоритмов ИНС с распознаванием неисправностей и рекомендациями по реализации дальнейших ее действий.




Рис. 3. Архитектура нейро-нечеткой системы мониторинга ЭТСОН

III. Порядок построения искусственной нейронной сети для ЭТСОН

Рассмотрим порядок построения нейронной сети на примере ПВСД ЭГПА. Использование при прогнозировании технического состояния ЭГПА большого числа контролируемых переменных ПВСД (напряжений, токов, частичных разрядов и температуры обмоток статора) позволяет повысить достоверность и эффективность процедуры мониторинга. Для практического использования модуля ИНС вначале определяют его размеры, т.е. число входов и выходов (в рассматриваемом примере целесообразно эти значения выбрать равными соответственно 3 и 1).

Затем архитектура сети формируется исходя из алгоритма обучения, минимизации среднеквадратической ошибки результатов мониторинга и перспектив прогнозирования технического состояния ПВСД с определением его остаточного ресурса.

Прежде, чем встраивать блок ИНС (рис. 3) в подсистему интерпретации информации в структуре ВСМП, необходимо изучить функционирование трех ИНС с входами различной архитектуры. При этом входы этих ИНС имеют разный размер и, как следствие, их структуры, выбранные после фазы обучения, будут отличаться и иметь разное число внутренних слоев и число нейронов в этих слоях. После выбора структуры сети ВСМП технического состояния ПВСД на основе подробного параметрического исследования трех ИНС, необходимо решить следующие основные задачи.

A. Окончательный выбор диагностируемых переменных

Анализ натуральных экспериментальных исследований различных компрессорных станций позволил сделать вывод о том, что наиболее информативными входными переменными, характеризующими техническое состояние изоляции обмотки статора СТД-12500-2, являются: температура медной обмотки, интенсивность частичных разрядов и уровень перенапряжений питающей сети. Именно эти параметры могут адекватно оценить техническое состояние машины и спрогнозировать наступление нештатных режимов. Кроме того, эти переменные доступны прямому измерению штатными техническими средствами и непосредственному их представлению в нейронной базе знаний (НБЗ). В публикациях [1-3, 22] представлены результаты замеров

данных эксплуатационных факторов и общая статистика наблюдений за период с 1985 по 2014 годы с фиксацией 62 случаев выхода из строя СТД-12500-2.

В. Синтез конструкции нейронной базы знаний

Для создания на основе ИНС модели, описывающей исправное и неисправное состояния статорной обмотки ПВСД ЭГПА, необходимо синтезировать такую конструкцию НБЗ, в которой содержалась бы достаточная для решения задачи информация о возможных дефектах, возникающих в различных режимах работы ЭГПА-12,5. С этой целью, на основе анализа априорной статистической информации о возможных неисправностях (и симуляции возможных нарушений) СТД-12500-2, все они группируются в 12 возможных видов (включая исправные состояния), и по каждому состоянию оцениваются текущие изменения трех выбранных ранее входных переменных в течение всего периода измерений. В итоге НБЗ каждой переменной составила массив из 3000 различных значений (векторов), характеризующих возможные режимы работы электродвигателя. Это значение, соответствующее количеству замеров и результатов поставленных экспериментов, необходимо ввести в конструкцию ИНС, которая представлена табл. 1.

Таблица 1. КОНСТРУКЦИЯ НБЗ НА ОСНОВЕ ИНС

Тип неисправности обмотки статора	Символ	Код ИНС
Перегрев в пазовой части рачотки	QP	000 000 000 001
Перегрев в лобовой части обмотки	QL	000 000 000 010
Перегрев на выводах	QU	000 000 000 100
Перегрев при запуске агрегата	QS	000 000 001 000
Перенапряжения выхода из синхронизма	QA	000 000 010 000
Перенапряжения при дребезге контактов	QC	000 000 100 000
Перенапряжения при ОЗЗ	QZ	000 001 000 000
Перенапряжения при МКЗ	QT	000 010 000 000
Загрязнение масляно-графитовое	QM	000 100 000 000
Дефект изоляции в пазовой части	QI	001 000 000 000
Дефект изоляции в лобовой части	QQ	010 000 000 000
Отсутствие дефектов изоляции	QN	100 000 000 000

С. Создание блока ИНС

Сформированные нейронные сети являются многоуровневыми с оптимальным алгоритмом своего обучения. Для встраивания блока ИНС в ВСМП ПВСД предлагается исследовать 3 нейронные сети (рис. 4).

После фазы их тестирования и сравнения между собой, можно выбрать наиболее подходящую для решения всего комплекса задач прогнозирования ИНС. При этом этапы конструирования и пригодности нейронных сетей разделяются на три фазы. Первая фаза связана с выбором входов и конструкцией НБЗ, исходя из файлов, полученных при анализе всех трех упомянутых параметров мониторинга. Вторая фаза связана с выбором выходов сетей (для каждой отдельно) и их кодов, а третья фаза – с выбором архитектуры сетей.

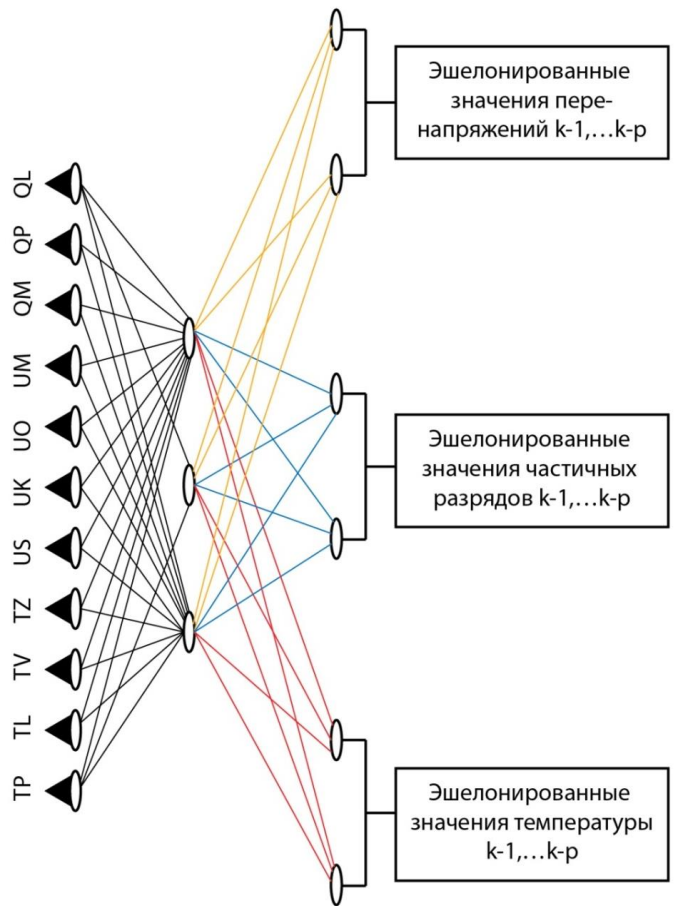


Рис. 4. Структура третьей искусственной нейронной сети

Д. Определение тестов селекционированных сетей

При числе используемых входов блока ИНС, равном десяти (на рис. 4 – $p = 10$), в табл. 2 для каждой контролируемой переменной приведены полученные результаты тестирования, согласно работам [1-3].

Таблица 2. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ ТРЕХ ИНС

№ ИНС	Число нейронов				Средне-квadraticная ошибка
	Входной слой	Внутренний слой	Выходной слой		
1	10	13	11		$3,24221 \cdot 10^{-15}$
2	20	8	11		$3,71314 \cdot 10^{-16}$
3	30	6	11		$3,26580 \cdot 10^{-17}$

Для трех сетей этап селекционирования выполняется после того, как вторая сеть завершает свое тестирование после 148 презентаций каждого примера. При этом тестирование выполняется в 2 этапа: на первом этапе сеть выполняет 100 повторяющихся исследований для каждого примера неисправного состояния, на втором этапе эти состояния вновь вводятся в программу тестирования, которая прекращается после 48 итераций со среднеквадратичной ошибкой результатов тестирования, равной $3,7 \cdot 10^{-16}$ (рис. 5).

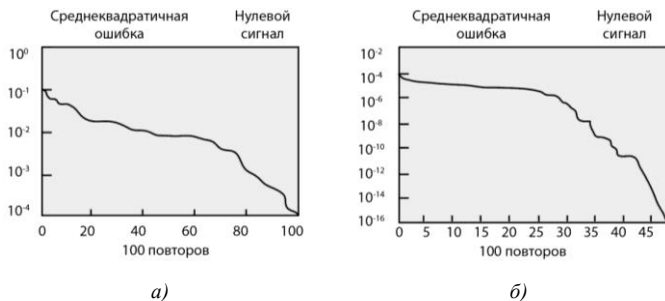


Рис. 5. Эволюция среднеквадратичной ошибки для ИНС

Для трех сетей этап селекционирования выполняется после того, как вторая сеть завершает свое тестирование после 148 презентаций каждого примера. При этом тестирование выполняется в 2 этапа: на первом этапе сеть осуществляет 100 повторяющихся исследований для каждого примера неисправного состояния, на втором этапе эти состояния снова вводятся в программу тестирования, которая прекращается после 48 итераций со среднеквадратичной ошибкой результатов тестирования, равной $3,7 \cdot 10^{-16}$ (рис. 5).

II. ТЕСТЫ СЕТЕЙ НЕЙРОНОВ

После построения трех сетей нейронов и достижения желаемых точностных показателей при их обучении, важнейшим этапом становится их комплексное сопоставление между собой. При этом сравнение производится путем тестирования входов и выходов каждой ИНС. Эта процедура связана с фазой обучения и определением базы тестов, с помощью которых приступают к тестированию способности ИНС распознавать “скрытые” дефекты, ранее не рассматриваемые при оценке работоспособности ЭГПА, и оценки способности ИНС к обобщению результатов.

Так ВСМП технического состояния ПВСД типа СТД-12500-2 предусматривал выбор из трех ИНС (рис. 4) наилучшей сети путем их тестирования для ранее приведенных дефектов (табл. 1). Тест позволил идентифицировать их с большой точностью, что подтверждается значениями среднеквадратичных ошибок результатов диагностирования, которые близки нулю (табл. 2). При тестировании третьей сети для дефектов СТД-125000-2, которые были изучены на фазе обучения сети, результаты ее моделирования для неисправностей, связанных с перегревом в пазовой части ротора, представлены в табл. 3.

Таблица 3. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ ТРЕТЬЕЙ ИНС

Выходы ИНС	Нагрузка, % номинала					
	90 %	80 %	60 %	40 %	20 %	10 %
1	1,0000	1,0000	1,0000	0,8570	1,0000	0,9605
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0005
3	0,0000	0,0000	0,0002	0,0000	0,0000	0,0034
4	0,0049	0,0000	0,0000	0,0000	0,0000	0,0000
5	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
6	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
7	0,0000	0,0000	0,0000	0,0057	0,0000	0,0000
8	0,2310	0,0000	0,0067	0,0000	0,0000	0,0000
9	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

10	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
11	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Согласно анализу результатов, полученных на фазе теста всех трех ИНС, выявлено, что третья сеть нейронов (см. табл. 2 и табл. 3) наиболее производительна и, следовательно, именно она целесообразна для применения в ВСМП ЭГПА. Что же касается выходов третьей сети, которые близки к желаемому значению, то можно сделать вывод, что они должны быть приближены к “0” или к “1”, чтобы обеспечить достоверность идентификации неисправности в изоляции статора ПВСД с указанием первопричины и места его появления. При этом обоснование объективных рекомендаций для устранения подобных неисправностей является главным результатом работы ВСМП на базе ИНС.

III. СОПОСТАВЛЕНИЕ РЕЗУЛЬТАТОВ ПРОГНОЗИРОВАНИЯ ТС ЭГПА

Для сопоставления достоверности результатов прогнозирования ТС ПВСД ЭГПА различными методами получены кривые прогнозов токов статора СТД-12500-2 (рис. 6) методами Бокса-Дженкинса (кривая *в*) с ошибкой (34–127)%, ИНС Ворда (кривая *б*) с ошибкой (27–84)% и методом временных рядов АДСС (кривая *з*) с ошибкой (11–58)%. Однако, спецификой функционирования ЭГПА является большая инерционность (постоянные времени), включая изменения тепловых режимов и параметров частичных разрядов.




Рис. 6. Прогнозирование тока статора электродвигателя СТД-12500-2: а – фактический временной ряд, б – прогноз, полученный с использованием ИНС (Ворда), в – прогноз, полученный с использованием модели Бокса-Дженкинса, г – прогноз, полученный с использованием метода временных рядов.

Таким образом, рациональный выбор метода прогнозирования технического состояния конкретного ЭГПА определяется совокупностью условий, режимов работы магистральных газопроводов и различными системными особенностями функционирования газоперекачивающей техники на компрессорных станциях.

Практические результаты измерений интенсивности частичных разрядов в обмотках приводных двигателей представлены в соответствующих окнах на рис. 7.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- [1] Пужайло А.Ф. и др. Энергосбережение и автоматизация электрооборудования компрессорных станций // Под ред. О.В. Крюкова / Нижний Новгород. Вектор ТиС. Т. 2. 2011. – 664 с.
- [2] Крюков О.В., Титов В.Г. Анализ пусковых режимов электроприводных газоперекачивающих агрегатов // Известия ВУЗов. Электромеханика. 2012. № 3. С. 29-35.
- [3] Крюков О.В., Степанов С.Е. Пути модернизации электроприводных газоперекачивающих агрегатов // Электромеханічні І енергозберігаючі системи. 2012. № 3 (19). С. 209-212.
- [4] Kryukov O.V. Scientific background for the development of intelligent electric drives for oil and gas process units // Вестник ЮУрГУ. Серия: Энергетика. 2017. Т. 17. № 1. С. 56-62.
- [5] Крюков О.В. Комплексная система мониторинга и управления электроприводными газоперекачивающими агрегатами // В сборнике: Труды МНПК «Передовые информационные технологии, средства и системы автоматизации и их внедрение на российских предприятиях», АГА-2011, Москва: ИПУ РАН, 2011. – С. 329-350.
- [6] Крюков О.В. Синтез и анализ электроприводных агрегатов компрессорных станций при стохастических возмущениях // Электротехника. 2013. № 3. С. 22-27.
- [7] Крюков О.В. Алгоритмы быстрого преобразования Уолша в микропроцессорных системах управления электроприводом // Известия ВУЗов. Электромеханика. 2005. № 4. С. 39-44.
- [8] Захаров П.А., Крюков О.В., Киянов Н.В. Встроенная система диагностирования и прогнозирования ЭГПА // Контроль. Диагностика. 2008. № 11. С. 43-49.
- [9] Милов В.Р., Шалашов И.В. Процедуры прогнозирования и принятия решений в системе технического обслуживания и ремонта // Автоматизация в промышленности. 2010. № 8. – С. 47-49.
- [10] Крюков О.В. Подход к прогнозированию технического состояния электроприводных ГПА // Приборы и системы. Управление, контроль, диагностика. 2016. № 9. С. 30-34.
- [11] Kiyarov N.V., Pribytkov D.N., Gorbatushkov A.V. A Concept for the development of invariant automated electric drives for the water recycling systems with fan cooling towers // Russian Electrical Engineering. 2007. Т. 78. № 11. С. 621-627.
- [12] Крюков О.В. Методология и средства нейро-нечеткого прогнозирования состояния электроприводных ГПА // Электротехника, 2012, №9. – С.52-57.
- [13] Бабичев С.А., Захаров П.А., Крюков О.В. Мониторинг технического состояния приводных электродвигателей газоперекачивающих агрегатов // Контроль. Диагностика. 2009. № 7. – С. 33-39.
- [14] Репин Д.Г., Крюков О.В. Концепты системы мониторинга технического состояния компрессорных станций // Контроль. Диагностика. 2017. № 12. С. 30-35.
- [15] Крюков О.В. Архитектура систем мониторинга технического состояния трубопроводов обвязки компрессорных станций // Приборы и системы. Управление, контроль, диагностика. 2018. № 5. С. 48-54.
- [16] Крюков О.В., Репин Д.Г. Системы оперативного мониторинга технического состояния энергоустановок для энергетической безопасности компрессорных станций // Газовая промышленность. 2014. № 712. – С. 84-90.
- [17] Крюков О.В. Мониторинг условий эксплуатации электродвигателей газоперекачивающих агрегатов // Контроль. Диагностика. 2016. № 12. С. 50-58.
- [18] Серебряков А.В., Крюков О.В. Универсальная система мониторинга электродвигателей ГПА // Известия ВУЗов. Электромеханика. 2016. № 4 (546). С. 74-81.
- [19] Крюков О.В., Серебряков А.В., Макриденко Л.А., Волков С.Н., Сарычев А.П., Кобельков Н.О. Мониторинг и прогнозирование технического состояния электромеханических систем энергетики // М.: АО «Корпорация ВНИИЭМ». – 2017.
- [20] Kryukov O.V., Serebryakov A.V. Artificial neural networks of technical state prediction of gas compressor units electric motors // Вестник

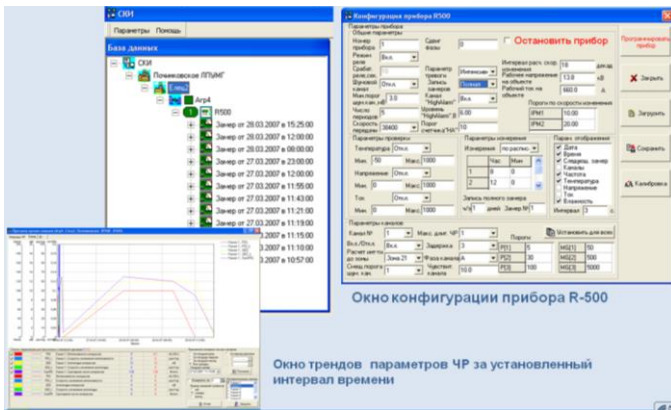


Рис. 7. Результаты компьютерного анализа измерений интенсивности частичных разрядов в изоляции статорных обмоток ЭГПА

IV. ВЫВОДЫ

1) Разработана система мониторинга оценки влияния эксплуатационных факторов ПВСД на ресурс изоляции статора, которая показала:

- нагрев обмоток в средней части двигателя на 23 °С выше, чем лобовых частей, а частота пробоев изоляции здесь составляет более 86 %. Кроме того, при внезапном останове машины температура растет еще на 15-20 °С, вызывая опасность теплового удара и перегрева обмоток;
- линейные напряжения на ЗРУ-10 кВ в течении 82 час наблюдений могут составлять $10,37 \div 10,91$ кВ, превосходя стандартные значения и имея значительные искажения по форме;
- механические нагрузки из-за электродинамических усилий в стержнях на обмотку статора машины незначительны даже при реакторном пуске ПВСД;
- все машины СТД-12500 имеют ЧР различной амплитуды и интенсивности, а «on-line» мониторинг ЧР позволяет адекватно оценивать ТС ПВСД.

2) Результаты исследований эффективности ВСМП ПВСД на основе методов нечеткой логики (Бокса-Дженкинса) и ИНС (сети Ворда) при прогнозировании технических параметров СТД-12500 в случае развития постепенных отказов показали, что они дают более точные результаты по сравнению с традиционными методами экстраполяции и позволяет принимать более адекватные и своевременные решения. При многошаговом прогнозировании быстрых процессов изменения токов в условиях отсутствия дополнительной информации на этапе идентификации модели применение метода прогнозирования на основе временных рядов дает более точный результат. Однако рациональный выбор метода прогнозирования технического состояния конкретного ЭГПА определяется совокупностью условий, режимов работы МГ и системными особенностями функционирования газоперекачивающей техники на компрессорных станциях магистральных газопроводов.

Южно-Уральского государственного университета. Серия: Энергетика. 2016. Т. 16. № 1. С. 66-74.

[21] Kryukov O.V. Methodology and tools for neuro-fuzzy prediction of the status of electric drives of gas-compressor units // Russian Electrical Engineering. 2012. Т. 83. N 9. – С. 516-520.

[22] Захаров П.А., Крюков О.В. Мониторинг и прогнозирование технического состояния ЭГПА КС ПХГ // Газовая промышленность. 2013. № 700. – С. 113-119.

