

УДК 621.438:004.032.26

ОБЗОР МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ГАЗОТУРБИННЫХ ДВИГАТЕЛЕЙ

А.И. Мухамеджанов, И.И. Хабибуллин

Рассмотрены некоторые проблемы, возникающие при эксплуатации газотурбинных двигателей, методы мониторинга, диагностики работы газотурбинного двигателя при эксплуатации и методы прогнозирования работы на основе анализа данных, машинного и глубокого обучения. Приведен краткий обзор методов машинного обучения для прогнозирования технического состояния газотурбинных двигателей.

Ключевые слова: газотурбинный двигатель, безопасность эксплуатации, проблемы эксплуатации, машинное обучение, глубокое обучение, искусственные нейронные сети, прогнозирование технического состояния, диагностика, мониторинг.

В ходе эксплуатации газотурбинных двигателей различного назначения возникают проблемы. По результатам анализа причин аварий газотурбинных двигателей в газотранспорте установлено [1], что наряду с техническими и технологическими причинами аварии обусловлены стихийными бедствиями (оползни, дождевые паводки, просадки грунта и др.). В работах [2, 3] отражено, что работа газотурбинного двигателя приводит к загрязнению воздушно-газового тракта, что ухудшает характеристики и параметры двигателя (расход воздуха, тяга (мощность), расход топлива, температура и давление газов в различных сечениях тракта) и приводит к эрозии, коррозии лопаточных венцов турбомашин, износу уплотнений тракта, загрязнению тракта образованием отложений в каналах охлаждения лопаток турбин и т. п. В статье [4] приведены основные причины возникновения аварийных и чрезвычайных ситуаций на компрессорных станциях магистральных газопроводов, возникающие из-за воспламенения масла, разрушения обвязочных газопроводов, попадания посторонних предметов в полость нагнетателя, поступления воспламеняющихся веществ через неплотности в запорно-регулирующей арматуре, нарушений специалистов технологического процесса, чрезмерного повышения температуры сжатого воздуха и перегрева частей трубопроводов компрессорной установки, пыльности и влажности засасываемого воздуха, разрядов статического электричества, повышения давления выше возможно допустимого, неправильного монтажа.

Рассмотрев краткий обзор проблем и неисправностей, возникающих в ходе эксплуатации компрессорных установок с газотурбинными двигателями, можно сделать вывод о том, что актуальность оценки технического состояния газотурбинного двигателя в виде мониторинга, диагностики и прогнозирования обеспечением бесперебойной работы без внепланового останова и безопасности работы без чрезвычайной ситуации очень высока.

Оценка технического состояния газотурбинного двигателя состоит из трех основных компонентов: мониторинг технического состояния газотурбинного двигателя, диагностика и прогнозирование неисправностей компонентов и систем газотурбинного двигателя (рис. 1).

В свою очередь, мониторинг, диагностику и прогнозирование можно также разделить на подкомпоненты (рис. 2).

В процессе мониторинга технического состояния периодически проверяется работа газотурбинного двигателя и его систем с одновременным ведением записей трендов. В основном мониторинг осуществляется удаленно, в операторной компрессорной станции, в связи с тенденцией развития «безлюдных технологий» в газовой отрасли Российской Федерации. Записи данных собираются несколькими датчиками, расположенными вдоль оборудования, затем возвращаются в инженерный отдел, где они анализируются и обрабатываются для диагностики любого непредвиденного события. Во время диагно-

стики обрабатывается информация о техническом состоянии газотурбинного двигателя для определения рисков, которые влияют на его работоспособность.



Рис. 1. Схема мониторинга, диагностики и прогнозирования состояния газовой турбины

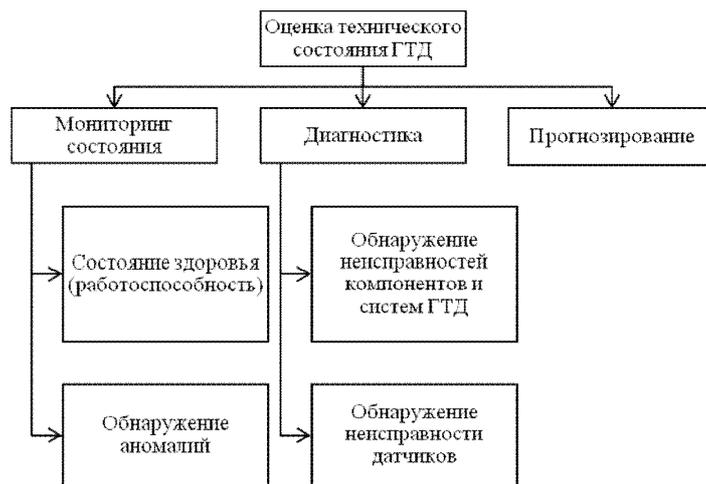


Рис. 2. Схема компонентов оценки технического состояния газотурбинного двигателя

Диагностика дополняет мониторинг технического состояния: мониторинг направлен на фиксацию производительности системы, а диагностика направлена на ее улучшение, поэтому оба компонента должны работать соответствующим образом.

Процесс прогнозирования технического состояния заключается в прогнозе состояния компонента и/или системы компонентов газотурбинного двигателя в будущей эксплуатации жизненного цикла изделия. Цель прогнозирования будущего состояния определяется с точки зрения предотвращения серьезных отказов компонентов или снижения производительности, связанного с эксплуатацией оборудования. Прогноз отказов фокусируется на прогнозировании состояния повреждения или частоты отказов компонента или системы компонентов в двигателе, в то время как прогноз деградации связан с более медленным снижением производительности на протяжении всего срока службы. Этот процесс на шаг опережает как мониторинг состояния, так и диагностику, но в то же время существует некоторая зависимость от того, как проводится диагностика.

На данный момент распространенные методы мониторинга, диагностики и прогнозирования основаны на традиционных алгоритмах, алгоритмах машинного и глубокого обучения [5].

Машинное обучение является общим вычислительным алгоритмическим подходом, который в настоящее время применяется в широком спектре областей (медицина, инженерное дело, транспорт, энергетика, машиностроение, информационные технологии, СМИ, искусство и т. д.) для автоматизированного построения аналитических моделей. В этом подходе используются алгоритмы для автоматического изучения и распознавания закономерностей на основе данных с применением этого обучения для принятия более эффективных решений. Эти алгоритмы машинного обучения и анализа данных позволяют обрабатывать значительный объем данных (особенно когда количество входных и выходных значений или сценариев принятия решений велико) и из них же извлекать знания с целью выявления скрытых структур, обеспечивают значительные возможности моделирования сложных нелинейных систем. Аналогично всем другим подходам, основанным на данных, модели машинного обучения не предполагают

физического понимания системы, но способны прогнозировать физические явления при точном обучении и наличии достаточных обучающих данных.

Методы машинного обучения делятся на три группы (рис. 3): обучение с учителем, обучение без учителя, обучение с подкреплением [6, 7].



Рис. 3. Типы обучения и предметные области, в которых они могут применяться [5, 6]

Вопросами оценки технического состояния (мониторинг, диагностика и прогнозирование) газотурбинного двигателя методами машинного обучения занимаются как зарубежные (в большей степени), так и российские исследователи. Данный обзор методов машинного обучения для прогнозирования и оценки технического состояния газотурбинного двигателя является кратким и не является исчерпывающим.

Далее будут приводиться лишь некоторые примеры работ по применению методов и алгоритмов машинного и глубокого обучения в задачах мониторинга, диагностики и прогнозирования технического состояния газотурбинного двигателя.

За последние несколько лет методы мониторинга технического состояния газотурбинного двигателя прошли путь от визуальных проверок и ручного анализа до более совершенных технологий. Например, датчиками постоянно фиксируются наиболее важные параметры состояния газотурбинного двигателя. С помощью полученных датчиками данных телеметрии современные методы анализа данных позволяют обрабатывать более сложные системы, бороться с неопределенностями, обусловленными стохастическим процессом деградации [8].

Далее рассмотрим некоторые примеры методов машинного обучения, используемые в мониторинге технического состояния газотурбинного двигателя, для определения состояния работоспособности газотурбинного двигателя и его систем и компонентов, а также для обнаружения аномалий в фиксируемых данных с целью исключения ложных срабатываний и повышения надежности.

Процесс перехода от наблюдаемых данных к математической модели стал основополагающим в промышленности для правильной идентификации работоспособности системы. Этот вопрос рассматривался с нескольких точек зрения, т. е. в некоторых исследованиях использовалась вся информация системы (газотурбинного двигателя) в целом, в другой части исследований газотурбинный двигатель рассматривался в виде отдельных компонентов и оценивалось состояние локально.

В работе [9] предложено использовать рекуррентные нейронные сети для идентификации и моделирования динамических характеристик газотурбинного двигателя с соблюдением структурной и параметрической адекватности аналитической модели. Результаты позволили получить адекватную модель для любого режима эксплуатации, получены хорошие эксплуатационные характеристики при запуске, наземном режиме и режиме полета.

Аналогичным образом в работе [10] сравниваются модели на основе искусственной нейронной сети и метода опорных векторов, используемые для мониторинга состояния работоспособности авиационного двигателя. Здесь модель искусственной нейронной сети продемонстрировала лучшую производительность в целях мониторинга технического состояния, в то время как модель метода опорных векторов показала лучшие результаты в качестве классификатора состояния работоспособности двигателя.

В работе [11] был предложен новый метод, который использует состязательное обучение искусственных нейронных сетей, основанное на трансферном обучении. Этот метод используется для улучшения системы мониторинга состояния работоспособности газотурбинного двигателя в изменяющихся условиях эксплуатации. Отметим, что авторы данного метода обсуждали проблему несогласованности эксплуатационных данных из-за изменений условий эксплуатации. Также здесь было отмечено, что системы мониторинга технического состояния, основанные на данных, в некоторых случаях были неэффективными. По этой причине предложенный метод показал высокую точность и производительность с учетом изменения условий работы газотурбинного двигателя.

Кроме искусственных нейронных сетей (глубокое обучение является подразделом машинного обучения) также широко используются «классические» методы машинного обучения. Например, в работе [12] используется вариационный байесовский метод для автоматической кластеризации модели гауссовой смеси с компонентами ее смеси, позволяющий облегчить распознавание стационарных и переходных режимов работы газотурбинного двигателя.

В работе [13] используются алгоритмы деревьев решений для анализа поведения работы газотурбинного двигателя в зависимости от изменения температуры. Аналогичным образом, но с использованием одноклассового подхода в работе [14] авторы предлагают сравнительное исследование подходов, управляемых данными, основанных на одноклассовых классификаторах. Одноклассовые классификаторы – это распространенные алгоритмы, используемые в нескольких областях, в которых модели учатся определять границы нормальных и аномальных выборок.

Кроме того, методы машинного и глубокого обучения широко используются также для мониторинга таких параметров газотурбинного двигателя, как расход топлива и температура отработанных газов, а также для отслеживания качества и стабильности сгорания топлива, для оценки выбросов оксидов серы и т. д. [15–17].

Обнаружение аномалий широко применяется для мониторинга технического состояния работы газотурбинного двигателя, а также для определения его работоспособности (состояния здоровья). Однако из-за того что современные промышленные системы являются чрезвычайно сложными, возникает множество проблем с классическими подходами к обнаружению аномалий. В связи с этим современные модели машинного обучения, которые способны автоматизировать построение подходов к обнаружению аномалий на основе доступных данных, разрешают проблему классических методов обнаружения аномалий. Далее будут рассмотрены некоторые из методов.

Известный алгоритм кластеризации DBSCAN был предложен в работе [18] для обнаружения и фильтрации выбросов. Результаты показали, что этот метод является надежным и быстрым. Кроме того, предложенный метод способен повысить производительность мониторинга состояния газотурбинного двигателя на основе искусственной нейронной сети, в том числе возможности прогнозирования технического состояния.

В работах [19–21] предлагается использовать метод обучения без учителя, основанный на сверточных нейронных сетях и автокодировщике, эффективно обнаруживающий аномалии в процессе мониторинга состояния газотурбинного двигателя. Сверточные нейронные сети значительно снижают вычислительные затраты и уменьшают количество обучающих данных благодаря способности извлекать важную информацию из пространственных входных данных. Структура автокодировщика идентифицирует любую ошибку, большую, чем обычные предварительно обученные ошибки. Комбинация этих подходов позволяет обрабатывать необычные сигналы более точно, чем другие традиционные методы машинного обучения.

Процесс диагностики направлен на анализ работы газотурбинного двигателя для выявления потенциальных неисправностей и их раннего предупреждения. В этом обзоре диагностика неисправностей будет рассматриваться как дополнение к описанному мониторингу состояния газотурбинного двигателя. Целью процесса мониторинга технического состояния газотурбинного двигателя является определение состояния работоспособности газотурбинного двигателя, в то время как диагностика направлена на понимание природы отклонения в производительности и характеристиках двигателя. Как было указано (см. рис. 2), диагностику можно разбить на два компонента: обнаружение неисправностей компонентов и систем газотурбинного двигателя и обнаружение неисправностей датчиков, установленных на двигателе.

Далее будут рассмотрены некоторые методы машинного и глубокого обучения, которые можно применить для диагностики двигателя.

При длительном периоде работы газотурбинного двигателя и различных условиях эксплуатации происходит временное или постоянное ухудшение характеристик двигателя. Следовательно, требуется надежная модель обнаружения и раннего предупреждения неисправностей в двигателе. В этом случае современные методы машинного обучения позволяют создавать более надежные модели и повышать эффективность обнаружения неисправностей.

В работе [22] для обнаружения неисправностей авторы сравнивали три метода классификации машинного обучения – случайный лес, метод k -ближайших соседей, логистическая регрессия. Наиболее высокую производительность показал случайный лес в предложенном наборе данных. В данной работе сделан вывод о том, что в соответствии с набором данных, использованным для проведения исследования, результаты могут варьироваться, и в каждом случае необходимы конкретные эксперименты, направленные на поиск того метода, который дает наименьшую среднеквадратичную ошибку, наивысшую точность и адекватное время обучения модели.

Как и в предыдущем случае, в работе [23] использован случайный лес для определения неисправностей лопаток газотурбинного двигателя. Для этого использовались оцифрованные сигналы в разные моменты времени, а также учитывались соответствующие исправные и неисправные состояния двигателя. Результаты показали очень хорошую производительность при определении неисправностей лопаток двигателя, и она превзошла все три альтернативных подхода к классификации (искусственные нейронные сети, деревья решений для классификации и регрессии и k -ближайший сосед) с точки зрения точности и полноты модели.

Аналогичным образом в работах [24–29] использовались искусственные нейронные сети (сверточные и рекуррентные сети, Extreme Learning Machine и др.) совместно в виде ансамблей, так и отдельно с классическими методами машинного обучения (SVM, PCA, различные ансамбли в виде бустинга, бэггинга, стекинга и др.) для обнаружения и раннего предупреждения неисправностей газотурбинного двигателя. В зависимости от целей, видов и типов неисправностей, чистоты, шумности и объема данных, а также режимов работы двигателя и условий эксплуатации эти методы показали высокую точность классификации неисправностей, быстроту и производительность, устойчивость к шумным данным и внезапным отказам.

Датчики в газотурбинном двигателе играют решающую роль в мониторинге технического состояния и обнаружении неисправностей. Сбои в измерениях датчиков часто могут привести к серьезным проблемам, влияющим на безопасность и производительность двигателя. Для диагностики неисправностей датчиков также широко используются методы машинного обучения.

В работе [30] был предложен метод, в котором была разработана интеграция квадратного корневого кубатурного фильтра Калмана и DBSCAN для выделения признаков неисправности датчика в зависимости от технологического и измерительного шума, в том числе для обнаружения и локализации неисправных датчиков. Схема оценки для отслеживания эволюции и классификации отказов датчиков была выполнена на основе невязок. Эксперименты показали, что этот подход более эффективен и надежен, чем обычные методы. Схожая методика использовалась в работе [31], где подход был основан на вейвлет-энтропии энергии и методе опорных вектор для регрессии. Этот подход показал почти 90 %-ю точность при более коротком времени диагностики.

Эффективный подход [32] в виде генетического алгоритма показал высокую производительность и точность в определении неисправностей датчиков, в отличие от других простых методов машинного обучения.

Искусственные нейронные сети в том числе широко применяются для диагностики неисправностей датчиков газотурбинного двигателя. В работе [33] был предложен метод для диагностики неисправностей датчиков, который основан на алгоритме искусственной нейронной сети обратного распространения. Результаты показали хорошую производительность и высокую точность определения неисправностей датчиков газотурбинного двигателя.

Прогнозирование технического состояния газотурбинного двигателя позволяет уменьшить количество непредвиденных событий/инцидентов в виде внезапных отказов и нежелательных условий эксплуа-

тации (нарушение режима эксплуатации) при снижении затрат на обслуживание и ремонт, а также максимизации прибыли за счет повышения коэффициента технической готовности системы. Таким образом, прогнозирование состояния позволяет прогнозировать техническое состояние газотурбинного двигателя в некотором будущем моменте времени на основе исторических данных телеметрии, условий эксплуатации и обнаруженных неисправностей в прошлом. Далее будут рассмотрены несколько примеров применения методов машинного обучения в задачах прогнозирования состояния газотурбинного двигателя.

В работе [34] предложен метод ограниченной линейной регрессии для прогнозирования деградации микрогазовых турбин с течением времени. Прежде всего деградация оценивалась по зависящим от времени переменным; затем она прогнозировалась по часам эксплуатации. По результатам исследований данный метод был успешно протестирован на нескольких испытательных системах и показал хорошую корреляцию с скорректированной мощностью.

Примеры использования нелинейной авторегрессионной нейронной сети и нейронной сети Элмана предложены в работе [35], где рассматривалась проблема мониторинга и прогнозирования работоспособности авиационных газотурбинных двигателей. Эти нейронные сети были разработаны для отслеживания динамики двух основных типов деградации – загрязнения компрессора и эрозии турбины. Результаты сравнения показали, что модель нейронной сети Элмана превосходит модель авторегрессионной нейронной сети.

В работах [36, 37] были рассмотрены взвешенные функции потерь типа асимметричных функций, байесовская иерархическая модель для прогнозирования оставшегося срока службы газотурбинного двигателя.

Широко применяются различные виды искусственных нейронных сетей в работах [38–43] для прогнозирования таких задач, как производительность газотурбинного двигателя для выработки электроэнергии, прогнозирование мощности, оценка процессов сгорания и выбросов отработанных газов и т. д.

В данной статье представлен краткий обзор основных проблем газотурбинного двигателя, возникающих в процессе эксплуатации, приведены примеры применения методов машинного и глубокого обучения в области мониторинга, диагностики и прогнозирования технического состояния газотурбинного двигателя, его компонентов и систем, что на данный момент является актуальной задачей в связи с интенсивным развитием и широким применением машинного и глубокого обучения. Отметим, что цифровизация и автоматизация газотурбинного двигателя, а также использование методов машинного и глубокого обучения позволяют повысить точность и эффективность алгоритмов, приводящих к улучшению производительности системы, отслеживать техническое состояние газотурбинного двигателя, диагностировать неисправности, сохранять срок службы снижением количества внезапных отказов, нарушений режима эксплуатации, внеплановых ремонтов, при этом минимизируя затраты и увеличивая прибыль за счет повышения коэффициента технической готовности.

СПИСОК ЛИТЕРАТУРЫ

1. *Габибов И.А., Алиев Э.Г.* Основные причины аварий в системе магистральных газопроводов // Актуальные вопросы современной науки: Сб. ст. материалов 7-й Междунар. науч.-практ. конф.: в 3 ч. Уфа: Дендра, 2017. С. 122–126.
2. *Абдуллин Б.Р. и др.* К оценке технического состояния газотурбинного двигателя, работающего в условиях загрязнения проточной части // Вестник Уфимского государственного авиационного технического университета. 2007. № 1. С. 22–25.
3. *Федосеев А.Ю., Калинин А.Ф.* Оценка изменения технического состояния осевого компрессора газотурбинного двигателя в процессе эксплуатации // Территория Нефтегаз. 2017. № 7-8. С. 112–117.
4. *Мукаев И.Р., Потапова С.О.* Основные принципы формирования системы предупреждения чрезвычайных ситуаций на компрессорных станциях магистральных газопроводов // Пожарная безопасность: проблемы и перспективы. 2018. № 9. С. 627–630.
5. *Хабибуллин И.И. и др.* Применение искусственных нейронных сетей при проектировании энергетических машин // Вестник КГТУ им. А.Н. Туполева. 2019. № 3. С. 70–76.
6. *Рашик С., Вахид М.* Python и машинное обучение: машинное и глубокое обучение с использованием Python, Scikit-Learn и Tensorflow. СПб.: Диалектика, 2020. 848 с.
7. *Гудфеллоу Я., Бенджио И., Курвилль А.* Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.

8. *De Castro-Cros M. et al.* Condition Assessment of Industrial Gas Turbine Compressor Using a Drift Soft Sensor Based in Autoencoder // *Sensors*. 2021. № 21. Article № 2708.
9. *Pogorelov G.I. et al.* Application of Neural Network Technology and Highperformance Computing for Identification and Real-Time Hardware-in-the-Loop Simulation of Gas Turbine Engines // *Procedia Engineering*. 2017. № 176. P. 402–408.
10. *Giorgi M.G.D., Campilongo S., Ficarella A.* A Diagnostics Tool for Aero-Engines Health Monitoring Using Machine Learning Technique // *Energy Procedia*. 2018. № 148. P. 860–867.
11. *Farahani H.S., Fatehi A., Shoorehdeli M.A.* On the Application of Domain Adversarial Neural Network to Fault Detection and Isolation in Power Plants // *Proc. of the 19th IEEE International Conference on Machine Learning and Applications*, Dec. 14–17, 2020, Miami, USA. P. 1132–1138.
12. *Zhang Y. et al.* Steady-State and Transient Operation Discrimination by Variational Bayesian Gaussian Mixture Models // *Proc. of the IEEE International Workshop on Machine Learning for Signal Processing, MLSP*, Sept. 22–25, 2013, Southampton, UK. P. 6–10.
13. *Zhandos A., Guo J.* An Approach Based on Decision Tree for Analysis of Behaviour with Combined Cycle Power Plant // *Proc. of the International Conference on Progress in Informatics and Computing*, Dec. 15–17, 2017, Nanjing, China. P. 415–419.
14. *Tan Y. et al.* A Comparative Investigation of Data-Driven Approaches Based on one-Class Classifiers for Condition Monitoring of Marine Machinery System // *Ocean Engineering*. 2020. № 201. Article № 107174.
15. *Liu J. et al.* Fault Detection for Gas Turbine Hot Components Based on a Convolutional Neural Network // *Energies*. 2018. № 11. Article № 2149.
16. *Sujatha G.K. et al.* Clean Coal Technology Using Inventive Materials for Monitoring SO₂ Emissions in Smart Power Plants // *AIP Conference Proceedings*. 2019. Vol. 2105. Iss. 1. Article № 020005.
17. *Gangopadhyay T. et al.* 3D Convolutional Selective Autoencoder for Instability Detection in Combustion Systems // *Energy and AI*. 2021. № 4. Article № 100067.
18. *Somehsaraei H.N. et al.* Automated Data Filtering Approach for ANN Modeling of Distributed Energy Systems: Exploring the Application of Machine Learning // *Energies*. 2020. № 13. Article № 3750.
19. *Lee G. et al.* Unsupervised Anomaly Detection of the Gas Turbine Operation via Convolutional Auto-Encoder // *Proc. of the Annual Conference of the Prognostics and Health Management Society*, June 8–10, 2020, Detroit, USA.
20. *Fu S. et al.* A Re-Optimized Deep Auto-Encoder for Gas Turbine Unsupervised Anomaly Detection // *Engineering Applications of Artificial Intelligence*. 2021. № 101. Article № 104199.
21. *Luo H., Zhong S.* Gas Turbine Engine Gas Path Anomaly Detection Using Deep Learning with Gaussian Distribution // *Proc. of the 2017 Prognostics and System Health Management Conference*, July 9–12, 2017, Harbin, China. Article № 17287513.
22. *Batayev N.* Gas Turbine Fault Classification Based on Machine Learning Supervised Techniques // *Proc. of the 14th International Conference on Electronics Computer and Computation*, Nov. 28 – Dec. 1, 2018, Kaskelen, Kazakhstan. P. 206–212.
23. *Maragoudakis M., Loukis E.* Using Ensemble Random Forests for the Extraction and Exploitation of Knowledge on Gas Turbine Blading Faults Identification // *Insight*. 2012. № 25. P. 80–104.
24. *Amozegar M., Khorasani K.* An Ensemble of Dynamic Neural Network Identifiers for Fault Detection and Isolation of Gas Turbine Engines // *Neural Networks*. 2016. № 76. P. 106–121.
25. *Wong P.K. et al.* Real-Time Fault Diagnosis for Gas Turbine Generator Systems Using Extreme Learning Machine // *Neurocomputing*. 2014. № 128. P. 249–257.
26. *Tahan M., Muhammad M., Abdul Karim Z.A.* A Multi-Nets ANN Model for Real-Time Performance-Based Automatic Fault Diagnosis of Industrial Gas Turbine Engines // *Journal of the Brazilian Society of Mechanical Sciences and Engineering*. 2017. № 39. P. 2865–2876.
27. *Amare D.F., Aklilu T.B., Gilani S.I.* Gas Path Fault Diagnostics Using a Hybrid Intelligent Method for Industrial Gas Turbine Engines // *Journal of the Brazilian Society of Mechanical Sciences and Engineering*. 2018. № 40. P. 1–17.
28. *Mohtasham Khani et al.* Deep-Learning-Based Crack Detection with Applications for the Structural Health Monitoring of Gas Turbines // *Structural Health Monitoring*. 2020. № 19. P. 1440–1452.
29. *Hong J. et al.* Remaining Useful Life Prediction Using Time-Frequency Feature and Multiple Recurrent Neural Networks // *Proc. of the IEEE International Conference on Emerging Technologies and Factory Automation*, Sept. 10–13, 2019, Zaragoza, Spain. P. 916–923.
30. *Zhu L. et al.* A Coupling Diagnosis Method for Sensor Faults Detection, Isolation and Estimation of Gas Turbine Engines // *Energies*. 2020. № 13. Article № 4976.
31. *Sun R. et al.* A Coupling Diagnosis Method of Sensors Faults in Gas Turbine Control System // *Energy*. 2020. № 205. Article № 117999.
32. *Hu Y. et al.* Sensor Fault Diagnosis of Gas Turbine Engines Using an Integrated Scheme Based on Improved Least Squares Support Vector Regression // *Journal of Aerospace Engineering*. 2020. № 234. P. 607–623.

33. Liu Y., Wang J., Shen Y. Research on Verification of Sensor Fault Diagnosis Based on BP Neural Network // Proc. of the 11th International Conference on Prognostics and System Health Management, Oct. 23–25, 2020, Jinan, China. P. 456–460.
34. Olsson T. et al. A Data-Driven Approach for Predicting Long-Term Degradation of a Fleet of Micro Gas Turbines // Energy and AI. 2021. № 4. Article № 100064.
35. Kiakojoori S., Khorasani K. Dynamic Neural Networks for Gas Turbine Engine Degradation Prediction, Health Monitoring and Prognosis // Neural Computing and Applications. 2016. № 27. P. 2157–2192.
36. Rengasamy D., Rothwel B., Figueredo G.P. Asymmetric Loss Functions for Deep Learning Early Predictions of Remaining Useful Life in Aerospace Gas Turbine Engines // Proc. of the International Joint Conference on Neural Networks, July 19–24, 2020, Glasgow, UK. P. 1–7.
37. Zaidan M.A. et al. Bayesian Hierarchical Models for Aerospace Gas Turbine Engine Prognostics // Expert Systems with Applications. 2015. № 42. P. 539–553.
38. Liu Z., Karimi I.A. Gas Turbine Performance Prediction via Machine Learning // Energy. 2020. № 192. Article № 116627.
39. Ravichandran T. et al. Data-Driven Performance Prediction Using Gas Turbine Sensory Signals // Proc. of the Canadian Conference on Electrical and Computer Engineering, April 26–29, 2020, London, Canada. Article № 20178609.
40. Alketbi S. et al. Predicting the Power of a Combined Cycle Power Plant Using Machine Learning Methods // Proc. of the 2020 IEEE International Conference on Communications, Computing, Cybersecurity, and Informatics, Nov. 3–5, 2020, Sharjah, United Arab Emirates.
41. Abdul-Wahab S.A. et al. Modelling the Clogging of Gas Turbine Filter Houses in Heavy-Duty Power Generation Systems // Mathematical and Computer Modelling of Dynamical Systems. 2020. № 26. P. 119–143.
42. Park Y. et al. Prediction of Operating Characteristics for Industrial Gas Turbine Combustor Using an Optimized Artificial Neural Network // Energy. 2020. № 213. Article № 118769.
43. Koleini I., Roudbari A., Marefat V. EGT Prediction of a Micro Gas Turbine Using Statistical and Artificial Intelligence Approach // IEEE Aerospace and Electronic Systems Magazine. 2018. № 33. P. 4–13.

Поступила в редколлегию 11.08.23

OVERVIEW OF MACHINE LEARNING METHODS FOR PREDICTING THE TECHNICAL STATE OF GAS TURBINE ENGINES

A.I. Mukhamedzhanov and I.I. Khabibullin

This article discusses some of the problems that arise during the operation of gas turbine engines, methods of monitoring, diagnostics of the operation of a gas turbine engine during operation and methods of forecasting work based on data analysis, machine and deep learning. A brief overview of machine learning methods for predicting the technical state of gas turbine engines is given.

Keywords: gas turbine engine, operational safety, operational problems, machine learning, deep learning, artificial neural networks, prediction of technical state, diagnostics, monitoring.

Мухамеджанов Амир Исмаилович – канд. техн. наук (КФУ, Казань)

E-mail: amir8919@mail.ru

Хабибуллин Ильмир Ильдарович – канд. техн. наук (АО «НИИтурбокомпрессор им. В.Б. Шнеппа», Казань)

E-mail: ilmir.khabibullin@niitk.ru