

Энергетика и электротехника

УДК 004.89

ИДЕНТИФИКАЦИЯ ДЕФЕКТОВ ПАРОВОЙ ТУРБИНЫ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

**Л.О. Антоненко, О.М. Проталинский, Ю.Ю. Ягупова, Т.Р. Феткуллин,
А.В. Андриюшин, Х.И. Берредэм¹**

Национальный исследовательский университет «МЭИ»
Россия, 111250, г. Москва, Красноказарменная, 14, стр. 1

E-mail: AntonenkoLO@mpei.ru, ProtalinskyOM@mpei.ru, YagupovaYY@mpei.ru,
FetkullinTR@mpei.ru, AndriushinAV@mpei.ru, BerredemK@mpei.ru

Аннотация. Рассматривается методика анализа, прогнозирования состояния и идентификации наличия неявных дефектов для паровых турбин с помощью параметрической диагностики на основе данных, измеряемых при эксплуатации турбины на тепловой электростанции. Проведена диагностика турбины Т-110/120-130. Оценка и прогнозирование состояния турбины Т-110/120-130 базируются на результатах анализа измеряемых параметров и расчета индекса технического состояния с помощью методов искусственного интеллекта и нейросетевых алгоритмов. Основной упор акцентируется на принципы построения систем параметрической диагностики для вспомогательной работы в качестве ассистентов на энергетических станциях. Предложенная методика позволяет разработать систему диагностики турбины Т-110/120-130 с возможностью выявления и идентификации неявных дефектов, прогнозирования состояния турбины на определенных временных промежутках.

Ключевые слова: энергетика, система диагностирования, диагностика энергетического оборудования, идентификация неявных дефектов, нейронные сети.



© Автор(ы), 2025

¹ Леонид Олегович Антоненко, аспирант кафедры автоматизированных систем управления тепловыми процессами.

Олег Мирославович Проталинский, доктор технических наук, профессор, профессор кафедры автоматизированных систем управления тепловыми процессами.

Юлия Юрьевна Ягупова, кандидат технических наук, старший преподаватель кафедры автоматизированных систем управления тепловыми процессами.

Тимур Равилович Феткуллин, аспирант кафедры автоматизированных систем управления тепловыми процессами.

Александр Васильевич Андриюшин, доктор технических наук, профессор, профессор кафедры автоматизированных систем управления тепловыми процессами.

Хароун Ильяс Берредэм, аспирант кафедры автоматизированных систем управления тепловыми процессами.

Введение

Одним из современных и актуальных направлений для исследования является задача своевременной диагностики состояния энергетического оборудования на тепловых и атомных электростанциях. Когда речь идет о критически важном для работы станции оборудовании, необходимо не только своевременно оценить состояние агрегата, но и удостовериться в его эффективной работе на некотором временном интервале. Диагностические методы, применяемые в отношении паротурбинного оборудования, можно разделить на четыре крупные группы: эксплуатационный мониторинг производственных параметров и энергетических показателей, динамический и спектральный анализ вибраций, физико-химический контроль смазочных сред и продуктов износа, неразрушающие методы контроля (ультразвук, акустическая эмиссия, вихретоковый контроль, тепловизионный контроль, визуальная и эндоскопическая инспекция). Предложенный в статье метод диагностирования использует нейросетевые модели для диагностики состояния турбины. Эксплуатационный мониторинг технологических и энергетических показателей основан на непрерывном сборе агрегированных энергетических метрик (давление, температура, КПД, расход) и применении пороговых критериев для выявления отклонений [1]. Эксплуатационные индикаторы отражают суммарный эффект уже развившейся деградации и позволяют выявить проблему на поздних стадиях, тогда как предложенный в статье метод способен выделять тонкие мультипараметрические корреляции между локальными сенсорными сигналами и ранними маркерами деградации. Нейросетевая диагностика позволяет системе получать предупреждение задолго до того, как агрегированные энергетические показатели выйдут за порог, и обеспечивает преимущество в своевременном планировании профилактических работ и снижении экономических потерь. Динамический и спектральный анализ вибраций использует частотный и временной анализ вибрационных сигналов для локализации дисбалансов, люфтов и усталостных повреждений посредством выделения характерных гармоник и их эволюции [2]. Спектральный анализ обладает высокой локальной чувствительностью к механическим аномалиям, однако он критически зависит от качества размещения датчиков, анализа перекрывающихся источников и экспертной интерпретации. Архитектура предложенного метода интегрирует вибрационные данные как элемент многомерного вектора признаков и использует нейронные сети для отделения устойчивых деградационных трендов от кратковременных возмущений. Дополнительно программа извлекает локальные частотно-амплитудные паттерны, формализуя их вклад в долгосрочную динамику, – в результате снижается вероятность ложных диагнозов и повышается автоматизация интерпретации сложных смешанных сигналов. Физико-химический контроль включает в себя лабораторный анализ масла (металлические включения, вязкость, кислотообразующая способность) для обнаружения износа и коррозии в опорах и уплотнениях [3]. Такой вид контроля обеспечивает высокую специфичность по отношению к износу, но носит периодический характер и обладает ограниченной оперативностью. Предложенная система, действуя в непрерывном режиме, способна интегрировать результаты лабораторных анализов как верификационные метки в процессе дообучения и одновременно генерировать предварительные сигналы тревоги. Такая методика позволяет эффективно использовать лабораторные пробы и дорогостоящие анализы, уменьшать частоту необоснованных проб и повышать оперативность обнаружения проблем. Неразрушающие методы контроля (ультразвук, акустическая эмиссия, вихретоковый контроль, тепловизионный контроль, визуальная и эндоскопическая

инспекция) основаны на адресных инструментальных обследованиях (для точной локализации трещин коррозионных очагов и других дефектов с высокой пространственной разрешающей способностью) [4]. Такие методы превосходны в точечной верификации, но их применение связано с периодическими остановками, трудоемкой подготовкой и высокой стоимостью, а также они не обеспечивают непрерывного мониторинга. Гибридная нейросетевая платформа сможет играть роль непрерывного «фильтра раннего оповещения», при этом именно она оптимизирует и сокращает объем проверок с методами неразрушающего контроля, направляя их только на зоны с высоким риском наличия дефекта, что экономически обосновано и уменьшает долю ненужных инспекций без утраты пространственной точности. Преимущества предложенной методики выражаются прежде всего в ее способности обеспечить раннюю, многопараметрическую и прогностическую диагностику – то есть в тех аспектах, где классические эксплуатационный мониторинг, вибрационный анализ, физико-химический анализ и методы неразрушающего контроля либо ограничены оперативностью и покрытием, либо требуют адресной валидации. Предлагаемая нейросетевая платформа, действуя как централизованный многоуровневый фильтр, не отменяет, но оптимально дополняет традиционные методы, переводя их применение в более экономически и технически обоснованный режим.

Задача исследования

Основной задачей исследования является разработка системы диагностики для турбин типа Т. В качестве примера система будет протестирована на турбине Т-110/120-130. Главной целью синтезированной системы будет поиск, выявление и идентификация неявных дефектов в турбинном оборудовании, а также прогнозирование его состояния на некоторых временных интервалах. С применением параметрической диагностики на основе интегрального индекса технического состояния (ИТС) в оборудовании типа паровых турбин Т-110/120-130 становятся доступными к обнаружению разнообразные неявные дефекты, которые традиционные методы визуального или единичного контрольного замера часто упускают. Основные типы выявляемых неявных дефектов:

1. Микротрещины в лопатках ротора, возникающие в результате циклических термомеханических напряжений на границах зерен и в зоне корневого перехода. Обнаруживаются посредством анализа модальных и гармонических составляющих вибрационного сигнала: даже незначимые, но систематические сдвиги частотных пиков и рост амплитуд высших гармоник приводят к сокращению ИТС и служат предвестниками усталостных разрушений [5].

2. Коррозионное истончение обечаек корпуса, внутренних камер и паропроводов, развивающееся вследствие агрессивного воздействия теплоносителей и продуктов сгорания. Проявляется в накоплении аномалий перепада давления и нелинейных градиентов температурного поля вдоль ходов газа. Сопоставление динамики этих параметров с нормативными кривыми в рамках вычисления ИТС позволяет количественно оценить глубину коррозионного поражения еще до возникновения видимых дефектов и межкристаллитных раковин [6].

3. Микролюфт в подшипниках и посадочных местах рабочих лопаток высокого давления, обусловленный выработкой баббитового слоя или износом подшипниковых вкладышей. Выражается в локальных возрастаниях температур смазочной системы и появлении асимметричных компонент вибрационной сигнатуры. Параметрический анализ данных температуры и виброметрии,

агрегированный в ИТС, позволяет выявить эту пробуксовку задолго до полной деградации подшипников и возникновения разрушений [7].

4. Адгезионные и кавитационно-абразивные отложения на теплообменных поверхностях турбины и камер сгорания, приводящие к формированию локальных «горячих точек», фиксируются через аномальные скачки локальной температуры и нелинейные искажения турбулентности газового потока. Учет статистики таких флуктуаций при расчете ИТС дает возможность оценить степень загрязненности и вычислить оптимальные интервалы химико-механической очистки [8].

5. Усталостное разрушение тонкостенных лопаток при частых переходах через резонансные частоты в режимах малых нагрузок выявляется посредством спектрального анализа акустических эмиссий и высокочастотных вибрационных помех. Интеграция этих данных в параметрическую модель на уровне ИТС обеспечивает раннюю детекцию кавитационно-акустических дефектов, что важно для предотвращения катастрофических отказов при высоконагруженных режимах [9].

Анализ этапов построения модели для идентификации дефектов и прогнозирования состояния

В качестве исходных данных для разработки методики использовались параметры турбины Т-110/120–130, полученные от тепловой электростанции. Для проведения расчетов использовались датасеты, содержащие характеристики турбины как при нормальной эксплуатации, так и при наличии выявленных дефектов. Дополнительно датасеты были дополнены критическими характеристиками турбины из нормативной документации. Совокупность полученных данных позволила полноценно оценить работу турбины с помощью нейронных сетей и спрогнозировать ее состояние на определенный временной интервал. Для реализации методики диагностики и прогнозирования состояния оборудования будет использована модель на основе турбины Т-110/120-130. Паровая турбина типа Т-110/120–130 служит ключевым звеном в преобразовании тепловой энергии водяного пара в механическую работу ротора, которая далее через редуктор и генератор трансформируется в электрическую [10]. Рабочий цикл начинается с того, что насыщенный или перегретый пар высокого давления, накопленный в барабане котлоагрегата, поступает по подающему коллектору на вход в ступень высокого давления турбины, где через направляющий аппарат и лопаточный аппарат осуществляется начальное расширение, сопровождаемое значительными перепадами давления и температуры. Далее последовательно следуют ступени среднего и низкого давления, каждая из которых снабжена собственным сегментом диафрагм, лопаток и отводящих камер, что обеспечивает поэтапное, регулируемое преобразование внутренней энергии пара в кинетическую энергию вращения ротора. Для полноценного анализа работы турбины в расчет ИТС турбины Т-110/120–130 следует интегрировать следующие группы параметров:

- входные параметры: давление и температура перегретого пара, расход рабочего пара, влажность пара (содержание влаги), энтальпия и массовый расход;
- параметры внутри турбины: локальные температуры корпуса на каждой ступени, перепады давления и энтальпии между ступенями;
- выходные параметры: давление и температура отработавшего пара, расход конденсата, тепловая эффективность (коэффициент использования тепла), нагрузка на ротор (крутящий момент, скорость вращения).

Корреляция каждой группы показателей с величиной ИТС позволяет достоверно определить тип выявленного дефекта. Рост перепада давления с

одновременным снижением тепловой эффективности указывает на коррозию обечаяек, а увеличение уровня высокочастотной акустической эмиссии при стабильных вибрационных параметрах – на кавитационное разрушение лопаток. Комплексный учет этих параметров обеспечивает раннюю и точную идентификацию неявных дефектов турбинного оборудования и позволяет спланировать превентивные ремонтные мероприятия до возникновения отказов.




Рис. 1. Функциональная схема диагностической системы

Функциональная схема представлена на рис. 1. Параметрическая диагностика паровой турбины Т-110/120-130 представляет собой многокомпонентную архитектуру, в которой изначально параметры рабочего пара (давление рабочего пара, температура, массовый расход, частоты вращения, значения энтальпии и влажности пара) поступают на вход первой нейросети, реализованной в виде гибридного LSTM-Dense конвейера. Внутри ИНС₁ рекуррентные LSTM-ячейки обеспечивают хранение и обновление долгосрочных временных зависимостей между последовательными выборками сигналов, а последующие полносвязные слои выполняют нелинейную агрегацию выделенных признаков. Такая архитектура помогает не только идентифицировать скрытые усталостные и коррозионные дефекты, но и

рассчитать ИТС. Полученный в ИНС₁ вектор ИТС, отражающий совокупный уровень деградации узловых элементов, передается вместе с исходным массивом измеренных параметров на вход второй нейросети (ИНС₂), в которой пространственно-временная обработка осуществляется через последовательность сверточных блоков для локального выделения аномальных паттернов в частотной и амплитудной характеристиках, после чего рекуррентный LSTM-модуль агрегирует полученные локальные признаки в глобальное представление временного тренда. Финальный полносвязный выходной слой ИНС₂ генерирует прогноз динамики ИТС, давая возможность определить ключевые рабочие характеристики турбины на заданный горизонт времени. Модель обеспечивает не только диагностику текущего состояния, но и предикцию вероятности отказа и оценки остаточного ресурса и позволяет энергопредприятиям планировать профилактическое обслуживание с учетом фактического состояния оборудования и снижать риски внеплановых простоев.

Архитектуры нейронных сетей

Для обучения и проверки работы нейронных сетей использовались данные, представленные ежедневной выборкой за интервал с 2022 до начала 2025 года. Дополнительно по нормативной технической документации были добавлены критические состояния турбины, характеризующие наличие дефектов. Итоговый массив данных состоял из 1460 точек. Исходные данные относятся к разряду средней длины для задач временных рядов. Ряды достаточно длинные, чтобы уловить сезонные и годовые эффекты, но не избыточно большие для обучения компактных глубоких моделей. Каждый элемент ряда содержал набор синхронизированных признаков: давление рабочего пара, температура, массовый расход, частоты вращения, значения энтальпии и влажности пара. Параллельно с этими признаками рассчитывался интегральный индекс технического состояния по нормативной методике для соответствующего дня, используемый далее как эталон при обучении ИНС₁ и как один из признаков при обучении ИНС₂. Важный ориентир эксперимента – целевые результаты: ИНС₁ должна была вычислить значения ИТС на историческом интервале 2022–2025 г. на основании многопараметрических сигналов, а ИНС₂ – построить адекватный ИТС. В качестве предобработки данных все каналы были синхронизированы по единому временному штампу, локальные пропуски (до нескольких последовательных дней) заполнялись интерполяцией, тогда как продолжительные разрывы и явные артефакты фиксировались и исключались из обучающей подвыборки. Такие параметры помечались для отдельного анализа, чтобы не внедрять в модель ошибочные паттерны. В силу задач двухуровневой архитектуры применялась разная логика окон. Для ИНС₁ (оценка текущего ИТС) использовалось окно исторической длины, равное 30 дням. Предложенная историческая дистанция дает возможность LSTM-подсети аккумулировать локальные месячные тренды и сглаживать кратковременные возмущения. На вход ИНС₁ получало матрицу из 30 дней со всеми параметрами работы турбины. Для ИНС₂ (многодневный прогноз) применялось более длинное окно в 90 дней. Сначала выделялись локальные частотно-амплитудные паттерны в пределах этого окна, а затем последовательность извлеченных локальных признаков агрегировалась для построения прогноза. С учетом временной природы данных разбиение на обучающую, валидационную и тестовую подвыборки выполнялось по времени. Для обучения использовался период с 2022 до 2024 года. Для валидации информации о первых шести месяцах 2025 года итоговая оценка включала прогноз работы

турбины до 2027 года. Для первой нейронной сети использовалась валидация методом hold out, при котором исходная размеченная выборка делится на две части: обучающую и отложенную (тестовую, hold-out). Для второй нейронной сети использовалась Expanding Window Validation (валидация расширяющегося окна) – стратегия валидации моделей временных рядов, при которой обучающее множество постепенно расширяется с добавлением новых данных. Первая нейронная сеть (ИНС₁), построенная на гибридной архитектуре LSTM–Dense, представляет собой многоуровневый аналитический модуль, задача которого заключается в преобразовании многомерных временных рядов эксплуатационных параметров турбины Т-110/120-130 в интегральный показатель ее технического состояния. На вход ИНС₁ поступает набор синхронных измерений – давление и температура перегретого пара, массовый расход, скорость вращения ротора, энтальпия и влажность среды, которые в совокупности характеризуют текущий режим работы и динамику износа узлов. Блок LSTM, располагаясь в начале сети, осуществляет селективную агрегацию предыдущих состояний и новых поступающих сигналов благодаря специализированным механизмам управления потоком информации. Такие механизмы могут удерживать в памяти ключевые тренды деградации оборудования и одновременно отбрасывать малозначимые шумы. Полученные временные представления затем проходят через серию полносвязных слоев, где происходит нелинейная компиляция извлеченных признаков, трансформация их пространственной структуры и отработка скрытых корреляций между датчиками. Рассчитанные выходы ИНС₁ формируют вектор поуровневых индексов технического состояния: сначала для каждого функционального узла турбины, а затем и общий индекс, отражающий совокупную степень деградации. В конечном итоге ИНС₁ обеспечивает высокоточную идентификацию дефектов и количественную оценку их влияния на надежность системы. Итоговые значения выходных параметров служат основой для последующих прогностических расчетов и принятия решений по техническому обслуживанию. По методике расчета ИТС для тепломеханического оборудования и паровых турбин ИТС паровой турбины будет учитывать ИТС [11]:

- арматуры в пределах турбины;
- корпуса цилиндра;
- подшипников турбины;
- ротора турбины;
- системы парораспределения;
- трубопроводов в пределах турбины.

Функциональная схема ИНС₁ представлена на рис. 2. Опишем подробнее работу ИНС₁. Входной вектор нейросети:

$$x_t = [P_{in}(t), T_{in}(t), m(t), w(t), h(t), \alpha_w(t)]^T, \quad (1)$$

где P – значения давления; T – значения температуры; m – значения массового расхода; w – значения скорости вращения; h – значения энтальпии; α – значения влажности пара на шаге t .




Рис. 2. Функциональная схема ИНС1

LSTM-блок [12]

Для учета временных зависимостей используется LSTM-ячейка, обновляющая внутреннее состояние $s(t)$ и вырабатывающая скрытое представление $h(t)$:

$$i_t = \sigma(W_i * x_t + U_i * h_{t-1} + b_i), \quad (2)$$

$$f_t = \sigma(W_f * x_t + U_f * h_{t-1} + b_f), \quad (3)$$

$$o_t = \sigma(W_o * x_t + U_o * h_{t-1} + b_o), \quad (4)$$

$$\tilde{c}_t = \tanh(W_c * x_t + U_c * h_{t-1} + b_c), \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (6)$$

$$h_t = o_t \odot \tanh(c_t), \quad (7)$$

где $i(t)$, $f(t)$, $o(t)$ – гейты; σ – сигмоида; Θ – поэлементное умножение; $W(*)$, $U(*)$, $b(*)$ – обучаемые параметры. LSTM аккумулирует накопленные во времени признаки деградации (усталость металла, коррозионные тенденции и т. п.).

Dense-блоки [13]

Скрытое состояние $h(t)$ подается на серию полносвязных слоев. Первый Dense-блок переводит многомерный временной эмбединг, который вышел из LSTM в пространство компактных высокоуровневых признаков, где нелинейности могут лучше отделять информативные факторы деградации от шума. Функционально первый слой комбинирует признаки, отвечающие за пространственно-временные характеристики, в признаки, пригодные для регрессии. Второй Dense-блок реализует окончательное отображение этих высокоуровневых признаков в целевой вектор прогнозов ИТС на все шаги горизонта. Такой разрыв обязанностей улучшает обучаемость, поскольку уменьшает нагрузку на один монолитный слой:

$$z^{(1)} = f\left(W^{(1)} * h_t + b^{(1)}\right), \quad (8)$$

$$z^{(2)} = f\left(W^{(2)} * z^{(1)} + b^{(2)}\right), \quad (9)$$

$$\hat{y} = W^{(3)} * z^{(2)} + b^{(3)}, \quad (10)$$

где f – функция ReLU, а последний слой $\hat{y}$ выдает вектор ИТС узлов и системы [ITS(1), ..., ITS(2), ITS(total)]. Сеть оптимизируется по среднеквадратичной ошибке между $\hat{y}$ и опорными метками y_t (заранее определенными ИТС системы и узлов для конкретных значений параметров турбины):

$$\theta = \frac{1}{N} * \sum_{i=1}^N \left\| y^{(i)} - \hat{y}^{(i)} \right\|^2 \rightarrow \min. \quad (11)$$

Первая нейронная сеть (ИНС₁) выполняет несколько важных функций:

- фильтрация поступающей информации (входной гейт);
- управление сохранением исторических данных (гейт забывания);
- формирование выходного отклика (выходной гейт).

Благодаря гейтам LSTM умеет «выбирать», какие фрагменты временного ряда важны для долгосрочной памяти, а какие следует отбросить. Такая методика позволяет эффективно моделировать как краткосрочные, так и долгосрочные зависимости без эффекта затухающих или взрывающихся градиентов.

Вторая нейронная сеть (ИНС₂), основанная на последовательном сочетании сверточного (Conv1D + Pooling) и рекуррентного (LSTM) блоков, служит для прогностического анализа динамики технического состояния паровой турбины Т-110/120-130. На вход данной сети поступает расширенный набор признаков, включающий в себя как оригинальные эксплуатационные параметры (давление рабочего пара, температура, массовый расход, частоты вращения, значения энтальпии и влажности пара), так и рассчитанный предыдущей сетью интегральный индекс технического состояния. Сверточная подсеть выполняет локальное сканирование входных временных рядов с целью выявления мелкомасштабных аномалий и кратковременных возмущений, отражающихся в виде резких флуктуаций или «импульсных» артефактов в различных каналах данных. По результатам операций пулинга формируется компактный набор высокоуровневых признаков,

инвариантных к сдвигам и масштабу, что повышает устойчивость к шумовым выбросам и снижает избыточность информации. Вторым этапом полученные локальные признаки обрабатываются LSTM-модулем, способным аккумулировать и «запоминать» длительные тренды деградации оборудования, возникающие при циклических термовибрационных и коррозионных нагрузках. Рекуррентная ячейка, управляя потоком информации через интегративные механизмы, аккумулирует исторические паттерны ухудшения состояния. Накопленные данные позволяют сети отличать фазовые закономерности от случайных флуктуаций. Наконец, в полносвязном выходном слое ИНС₂ агрегирует результирующее временное представление и формирует прогноз интегрального индекса технического состояния на заранее заданный горизонт планирования. Такой подход обеспечивает раннее предсказание наступления критических состояний и способствует оптимизации графиков профилактического обслуживания, минимизируя неплановые простои и повышая общую эффективность эксплуатации энергокомплекса.




Рис. 3. Функциональная схема ИНС2

Функциональная схема ИНС2 представлена на рис. 3. Рассмотрим подробнее логику работы ИНС2. Вторая нейронная сеть (ИНС₂) предназначена для прогнозистического анализа технического состояния паровой турбины Т-110/120-130. Она использует на вход расширенный набор признаков, включающий агрегированные результаты диагностики ИНС₁ (ИТС) и исходные эксплуатационные параметры.

Архитектура ИНС₂ объединяет сверточный блок для локального выделения аномальных паттернов и рекуррентный LSTM-блок для учета долговременных зависимостей. При обучении ИНС₂ использовала среднеквадратичную ошибку между прогнозом и эталонными значениями. ИНС₂ включает в себя следующие функции и блоки:

1. Формирование входного тензора [14]. На вход ИНС₂ подается матрица

$$x = \begin{bmatrix} x_{t-n+1} \\ x_t \\ ИТС_t \end{bmatrix}, \quad (12)$$

где каждая строка $x(t)$ – вектор параметров $[P, T, m, w, h, \alpha]$, а $ИТС(t)$ – скалярный индекс технического состояния из ИНС₁.

2. Сверточный (Conv1D) блок [15]. Для каждого фильтра k и положения j выполняется одномерная свертка:

$$z_k(j) = f_2 \left(\sum_{i=0}^{m-1} w_{k,i} X_{j+i} + b_k \right), \quad (13)$$

где $w(k, i)$ – веса k -го ядра длины m ; $b(k)$ – смещение; $f(2)$ – нелинейность (ReLU). Данный блок позволяет обнаружить локальные аномалии (резкие скачки или «шумы») во входных признаках за последние m шагов.

3. Pooling [16]. Для уменьшения размерности и повышения устойчивости к сдвигам по времени применяется max-pooling:

$$p_k(l) = \max z_k(j), \quad (14)$$

где $p(k)$ – это максимум из l -го окна длины p в сверточном канале k , $z_k(j)$ – выход сверточного слоя (Conv1D) в канале k на позиции j .

4. LSTM-блок. На полученную карту признаков $P = [p_1, \dots, p(k)]$ накладывается LSTM-ячейка (формулы гейтов и обновления состояния $c(t)$, $h(t)$ как в ИНС₁), обеспечивающая учет длительных динамических трендов.

5. Выходной слой (Dense). Скрытое состояние LSTM $h(t)$ проходит через один полносвязный слой:

$$\hat{y} = W_0 * h_t + b_0, \quad (15)$$

где y – прогнозируемый индекс технического состояния через заданный горизонт.

Используя предложенную структуру, ИНС₂ сочетает локальное выделение аномалий (Conv1D + Pooling) с глобальным учетом временных зависимостей (LSTM), обеспечивая точное прогнозирование оставшегося ресурса и надежности турбины.

Тестирование системы диагностирования

График изменения индекса технического состояния (рис. 4) демонстрирует во времени обобщенную характеристику текущего состояния оборудования турбины Т-110/120-130. По вертикали отложено значение ИТС (обычно в шкале от 0 до 100), по горизонтали – время эксплуатации. На графике видны отдельные кривые, соответствующие основным функциональным узлам – арматуре, корпусу цилиндра, подшипникам, ротору, системе парораспределения и трубопроводам. График

представляет собой выходные данные по ИТС для двух нейронных сетей. На основе данных о работе турбины получены значения ИТС по параметрам турбины. Точность работы программы будет проверена с помощью методики RMSE. Абсолютных «регламентированных» порогов RMSE для задач прогнозирования технического состояния оборудования нет – RMSE всегда интерпретируется относительно масштаба целевой переменной. Рассчитанный прогноз на d дней дал предсказания:

$$y_1 = \begin{bmatrix} y_1 \\ \dots \\ y_d \end{bmatrix}, y_2 = \begin{bmatrix} ИТС_1 \\ \dots \\ ИТС_d \end{bmatrix}, \quad (16)$$

где y_1 – прогнозируемый ИТС на d дней; y_2 – ИТС, рассчитанным по методике Минэнерго для предсказанных рабочих параметров турбины. Тогда корень из среднеквадратичной ошибки

$$RMSE = \sqrt{\frac{1}{d} * \sum_{t=1}^d (y_t - ИТС_t)^2}, \quad (17)$$

где $RMSE$ – один скаляр, агрегирующий информацию обо всех ошибках на d дней. $RMSE$ дает оценку «типичной» (корня среднего квадрата) ошибки в тех же единицах, что и прогнозируемая величина. Нельзя оценивать качество модели по абсолютному значению $RMSE$ без контекста масштаба целевой переменной:

$$nRMSE = \frac{RMSE}{ИТС_{\max} - ИТС_{\min}}, \quad (18)$$

где $nRMSE$ – интерпретация $RMSE$ к масштабу $ИТС$; $ИТС(\max)$ – максимальное значение $ИТС = 100$; $ИТС(\min)$ – минимальное значение $ИТС = 0$. Итоговые значения варьируются в зависимости от количества прогнозируемых дней в диапазоне

$$0.04 \leq nRMSE \leq 0.14. \quad (19)$$




Рис. 4. Графическое представление результатов работы системы диагностирования

Полученные результаты показывают, что на выбранной дистанции прогнозирования RMSE изменяется от 4 до 14 %. При прогнозировании на несколько дней или месяцев погрешность не превышает 4–7 %, что в контексте ИТС (от 0 до 100) может являться допустимой погрешностью. Когда диапазон прогнозирования возрастает до двух лет, погрешность возрастает до 14 %, что может привести к ошибочным интерпретациям индекса технического состояния. Для дальнейших исследований диапазон прогнозирования будет уточнен с учетом первой нейронной сети, способной постоянно в режиме реально времени корректировать прогнозы второй нейронной сети.

Заключение

Предложенная система диагностики на основе нейросетевых моделей и параметрического анализа позволяет автоматизировать выявление неявных дефектов турбинного оборудования на тепловой электростанции. Практическая польза метода проявляется в нескольких взаимодополняющих эффектах:

- повышение чувствительности к многофакторным паттернам, недоступным классическим пороговым алгоритмам (позволяет фиксировать дефекты на этапе микроскопических проявлений);

- возможность количественной оценки тенденции деградации (прогноз ИТС) и тем самым формирование обоснованных графиков профилактических вмешательств, минимизирующих суммарные эксплуатационные затраты и риск незапланированных простоев.

Системный анализ ошибок прогноза служит оперативным индикатором деградации качества модели. Рост nRMSE или возрастающая доля дней с крупными отклонениями должны трактоваться как сигнал к пересмотру обучающей выборки, корректировке архитектуры или переработке стратегии предобработки данных. Технические ограничения метода и меры по их минимизации также очевидны – эффективность модели напрямую зависит от полноты и качества сенсорной сети, корректности расчета исходных ИТС и репрезентативности обучающих данных, поэтому для практического внедрения необходимы процедуры контроля целостности датчиков, синхронизации временных рядов и верификации нормативных весовых коэффициентов. Таким образом, предложенная методика для расчета ИТС конкретных узлов турбины T-110/120-130 в совокупности с современными методами ИИ-диагностики создает эффективный инструмент раннего выявления дефектов, прогнозирования оставшегося ресурса и своевременного предотвращения отказов оборудования.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Tahan M., Tsoutsanis E., Muhammad M., Abdul Karim Z.A.* Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines // *Applied Energy*. 2017. Vol. 198. Pp. 122–144. DOI: 10.1016/j.apenergy.2017.04.048. EDN: YDANFB
2. *Chang L.-Y., Chung Y.-N., Lin C.-H., Chen J.-L., Kuo C.-L., Chen S.-J.* Mechanical vibration fault detection for turbine generator using frequency spectral data and machine learning model: feasibility study of big data analysis // *Sensors and Materials*. 2018. Vol. 30. No. 4. Pp. 821–832. DOI: 10.18494/SAM.2018.1783
3. *Prabhakaran A., Jagga C.R.* Condition monitoring of steam turbine-generator through contamination analysis of used lubricating oil // *Tribology International*. 1999. Vol. 32. No. 3. Pp. 145–152. DOI: 10.1016/S0301-679X(99)00028-6

4. *Gomaa A., Jung J.-C., Lee Y.-K.* A study on non-destructive evaluation of the steam turbine L-0 blades // *Journal of KOSSE*. 2016. Vol. 12. No. 1. Pp. 59–71. DOI: 10.14248/JKOSSE.2016.12.1.059
5. *Ахмедова Э.Р., Тухватуллина А.Р.* Характерные и основные поломки и разрушения лопаток паровых и газовых турбин // Актуальные проблемы науки и техники: сб. науч. ст. по материалам VIII Междунар. науч.-практ. конф., Уфа, 15 апр. 2022 года. Уфа: Вестник науки, 2022. С. 22–28. EDN: FSDLWC
6. *Головин В.А., Печников Н.В., Щелков В.А., Цивадзе А.Ю.* Оценка срока эксплуатации теплообменных трубок конденсаторов пара на основе статистического анализа локальной язвенной коррозии по данным вихретокового контроля // *Физикохимия поверхности и защита материалов*. 2018. Т. 54. № 4S. С. 14–26. DOI: 10.1134/S004418561806013X. EDN: YOJSSL
7. *Лазарев Г.Б., Самородов Ю.Н.* Эрозионные повреждения подшипников турбогенераторов и мощных электродвигателей // *Энергия единой сети*. 2017. № 5(34). С. 44–60. EDN: ZUQTIL
8. *Чичирова Н.Д., Власов С.М., Чичиров А.А. [и др.]* Исследование структуры отложений в системах обратного охлаждения паровых турбин ТЭС // *Теплоэнергетика*. 2018. № 9. С. 94–102. DOI: 10.1134/S0040363618090023. EDN: XTWNGP
9. *Ахмедова Э.Р., Тухватуллина А.Р.* Характерные и основные поломки и разрушения лопаток паровых и газовых турбин // Актуальные проблемы науки и техники: сб. науч. ст. по материалам VIII Междунар. науч.-практ. конф., Уфа, 15 апр. 2022 года. Уфа: Вестник науки, 2022. С. 22–28. EDN: FSDLWC
10. РД 34.25.102-87 «Теплофикационный моноблок с турбиной Т-110/120-130 и барабанным котлом. Типовая пусковая схема»: руководящий документ / М-во энергетики СССР; разработ. ПО «Союзтехэнерго» [и др.]. М., 1986. 32 с.
11. Министерство энергетики Российской Федерации. Об утверждении Методики оценки технического состояния основного технологического оборудования и линий электропередачи электрических станций и электрических сетей: приказ от 26 июля 2017 г. № 676 // *Собрание законодательства РФ*. 2017. № 34. Ст. 5266.
12. *Hochreiter S., Schmidhuber J.* Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, No 8. Pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
13. *Huang G., Liu Z., van der Maaten L., Weinberger K.Q.* Densely Connected Convolutional Networks // *arXiv preprint*. 2016. arXiv:1608.06993
14. *Ong Y.J., Qiao M., Jadav D.* Temporal Tensor Transformation Network for Multivariate Time Series Prediction // *arXiv preprint*. 2020. arXiv:2001.01051
15. *Miron S., Albizzati A., Barazzetti L., Cordellini M., Mazzotti D., Pace A., Valli G., Vitale M., Zimoch I.* The Short-Term Prediction of Length of Day Using 1D Convolutional Neural Networks // *Sensors*. 2022. Vol. 22. No 23. Article 9517. DOI: 10.3390/s22239517. EDN: EZLMVK
16. *Hyun Ju.* Universal pooling – A new pooling method for convolutional neural networks / Ju Hyun, H. Seong, E. Kim // *Expert Systems with Applications*. 2021. Vol. 180. P. 115084. DOI: 10.1016/j.eswa.2021.115084. EDN: YMOKJW

Статья поступила в редакцию 17.07.2025

STEAM TURBINE FAULT IDENTIFICATION BASED ON NEURAL NETWORK MODELS

**L.O. Antonenko, O.M. Protalinsky, Yu.Yu. Yagupova, T.R. Fetkullin,
A.V. Andriushin, H.I. Berredem¹**

National Research University "Moscow Power Engineering Institute" (MPEI)
14, bld. 1, Krasnokazarmennaya st., Moscow, 111250, Russian Federation

E-mail: AntonenkoLO@mpei.ru, ProtalinskyOM@mpei.ru, YagupovaYY@mpei.ru,
FetkullinTR@mpei.ru, AndriushinAV@mpei.ru, BerredemK@mpei.ru

Abstract. *The paper discusses a methodology for analyzing, predicting the condition, and identifying latent defects in steam turbines using parametric diagnostics based on data measured during the operation of a turbine at a thermal power plant. The article presents a diagnostic analysis of a T-110/120-130 turbine. The assessment and prediction of the T-110/120-130 turbine's condition are based on the results of analyzing measured parameters and calculating a technical condition index using artificial intelligence methods and neural network algorithms. The main emphasis is placed on the principles of building parametric diagnostic systems for auxiliary work as assistants at power stations. The proposed methodology allows for the development of a diagnostic system for the T-110/120-130 turbine with the capability to detect and identify latent defects and predict the turbine's condition over specific time intervals.*

Keywords: *power engineering, diagnostic system, power equipment diagnostics, latent defect identification, neural networks.*

REFERENCES

1. Tahan M., Tsoutsanis E., Muhammad M., Abdul Karim Z.A. Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines // *Applied Energy*. 2017. Vol. 198. Pp. 122–144. DOI: 10.1016/j.apenergy.2017.04.048. EDN: YDANFB.
2. Chang L.-Y., Chung Y.-N., Lin C.-H., Chen J.-L., Kuo C.-L., Chen S.-J. Mechanical vibration fault detection for turbine generator using frequency spectral data and machine learning model: feasibility study of big data analysis // *Sensors and Materials*. 2018. Vol. 30. No. 4. Pp. 821–832. DOI: 10.18494/SAM.2018.1783.



© The Author(s), 2025

¹ Leonid O. Antonenko, Postgraduate Student, Dept. of Automated Control Systems for Thermal Processes.

Oleg M. Protalinsky (Dr. Sci. (Techn.)), Professor, Dept. of Automated Control Systems for Thermal Processes.

Yulia Yu. Yagupova (Ph.D. (Techn.)), Senior Lecturer, Dept. of Automated Control Systems for Thermal Processes.

Timur R. Fetkullin, Postgraduate Student, Dept. of Automated Control Systems for Thermal Processes.

Alexander V. Andriushin (Dr. Sci. (Techn.)), Professor, Dept. of Automated Control Systems for Thermal Processes.

Haroun I. Berredem, Postgraduate Student, Dept. of Automated Control Systems for Thermal Processes.

3. *Prabhakaran A., Jagga C.R.* Condition monitoring of steam turbine-generator through contamination analysis of used lubricating oil // *Tribology International*. 1999. Vol. 32. No. 3. Pp. 145–152. DOI: 10.1016/S0301-679X(99)00028-6.
4. *Gomaa A., Jung J.-C., Lee Y.-K.* A study on non-destructive evaluation of the steam turbine L-0 blades // *Journal of KOSSE*. 2016. Vol. 12. No. 1. Pp. 59–71. DOI: 10.14248/JKOSSE.2016.12.1.059.
5. *Ahmedova E.R., Tuhvatullina A.R.* Harakternye i osnovnye polomki i razrusheniya lopatok parovyh i gazovyh turbin [Characteristic and Main Failures and Fractures of Steam and Gas Turbine Blades] // *Aktualnye problemy nauki i tekhniki: sb. nauch. st. po materialam VIII Mezhdunar. nauch.-prakt. konf., Ufa, 15 apr. 2022 goda*. Ufa: Vestnik nauki, 2022. Pp. 22–28. EDN: FSDLWC. (In Russian)
6. *Golovin V.A., Pechnikov N.V., Shchelkov V.A., Civadze A.Yu.* Ocenka sroka eksploatatsii teploobmennyyh trubok kondensatorov para na osnove statisticheskogo analiza lokalnoy yazvennoy korrozii po dannym vihretokovogo kontrolya [Service Life Assessment of Steam Condenser Heat Exchanger Tubes Based on Statistical Analysis of Local Pitting Corrosion from Eddy Current Testing Data] // *Fizikohimiya po-verhnosti i zashchita materialov*. 2018. Vol. 54. No. 4S. Pp. 14–26. DOI: 10.1134/S004418561806013X. EDN: YOJSSL. (In Russian)
7. *Lazarev G.B., Samorodov Yu.N.* Eroziionnye povrezhdeniya podshipnikov turbogenera-torov i moshchnyyh elektrodvigatelej [Erosion Damage of Turbogenerator and High-Power Electric Motor Bearings] // *Energiya edinoj seti*. 2017. No. 5(34). Pp. 44–60. EDN: ZUQTIL. (In Russian)
8. *Chichirova N.D., Vlasov S.M., Chichirov A.A.* [i dr.] Issledovanie struktury otlozhe-nij v sistemah oborotnogo ohlazhdeniya parovyh turbin TES [Study of Deposit Structure in Steam Turbine Circulating Cooling Systems at Thermal Power Plants] // *Teploenergetika*. 2018. No. 9. Pp. 94–102. DOI: 10.1134/S0040363618090023. EDN: XTWNPG. (In Russian)
9. *Ahmedova E.R., Tuhvatullina A.R.* Harakternye i osnovnye polomki i razrusheniya lopatok parovyh i gazovyh turbin [Characteristic and Main Failures and Fractures of Steam and Gas Turbine Blades] // *Aktualnye problemy nauki i tekhniki: sb. nauch. st. po materialam VIII Mezhdunar. nauch.-prakt. konf., Ufa, 15 apr. 2022 goda*. Ufa: Vestnik nauki, 2022. Pp. 22–28. EDN: FSDLWC. (In Russian)
10. RD 34.25.102-87 "Teplofikacionnyj monoblok s turbinoj T-110/120-130 i baraban-nym kotlom. Tipovaya puskovaya schema": rukovodyashchij dokument / M-vo energetiki SSSR; razrabot [RD 34.25.102-87 "Cogeneration Monoblock with T-110/120-130 Turbine and Drum Boiler. Typical Start-Up Flow Diagram"]. PO "Soyuztekhenergo" [i dr.]. M., 1986. 32 p. (In Russian)
11. Ministerstvo energetiki Rossijskoj Federacii. Ob utverzhdenii Metodiki ocenki tekhnicheskogo sostoyaniya osnovnogo tekhnologicheskogo oborudovaniya i linij elektro-peredachi elektricheskikh stancij i elektricheskikh setej: prikaz ot 26 iyulya 2017 g. No. 676 [On the Approval of the Methodology for Assessing the Technical Condition of Main Process Equipment and Power Transmission Lines of Power Plants and Electric Grids: Order No. 676 of July 26, 2017] // *Sobranie zakonodatel'stva RF*. 2017. No. 34. St. 5266. (In Russian)
12. *Hochreiter S., Schmidhuber J.* Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, No 8. Pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
13. *Huang G., Liu Z., van der Maaten L., Weinberger K.Q.* Densely Connected Convolutional Networks // *arXiv preprint*. 2016. arXiv:1608.06993
14. *Ong Y.J., Qiao M., Jadav D.* Temporal Tensor Transformation Network for Multivariate Time Series Prediction // *arXiv preprint*. 2020. arXiv:2001.01051
15. *Miron S., Albizzati A., Barazzetti L., Cordellini M., Mazzotti D., Pace A., Valli G., Vitale M., Zimoch I.* The Short-Term Prediction of Length of Day Using 1D Convolutional Neural Networks // *Sensors*. 2022. Vol. 22. No 23. Article 9517. DOI: 10.3390/s22239517. EDN: EZLMVK
16. *Hyun Ju.* Universal pooling – A new pooling method for convolutional neural networks / Ju Hyun, H. Seong, E. Kim // *Expert Systems with Applications*. 2021. Vol. 180. P. 115084. DOI: 10.1016/j.eswa.2021.115084. EDN: YMOKJW

Original article submitted 17.07.2025