

УДК 004.81

Когнитивное моделирование систем оптимизации технологических параметров в работе тепловой электростанции

Бритвин Роман Максимович

rombritvin9@gmail.com

Комардин Максим Алексеевич

komardin.macsim@gmail.com

Панилов Павел Алексеевич^(*)

panilovp.a@bmstu.ru

Мартынов Николай Дмитриевич

martynov@bmstu.ru

МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация. Повышение эффективности и надежности тепловых электростанций (ТЭС) является ключевой задачей для современных энергосистем. Когнитивное моделирование выступает в качестве мощного инструмента для анализа сложных взаимосвязей между технологическими параметрами, выявления оптимальных решений и повышения эффективности работы станций. Этот метод способствует оптимизации использования ресурсов, снижению экологического воздействия, а также уменьшению рисков аварий и отказов. В данной работе рассматривается практическое применение когнитивного моделирования на ТЭС, подчеркивая его потенциал в повышении операционной эффективности, интеграции с современными системами управления и развитии устойчивой энергетики.

Ключевые слова: когнитивное моделирование, тепловые электростанции, оптимизация, рекомендательные системы, эффективность использования ресурсов

Cognitive modeling of systems for optimization of technological parameters in the operation of a thermal power plant

Britvin Roman Maksimovich

rombritvin9@gmail.com

Komardin Maxim Alekseevich

komardin.macsim@gmail.com

Panilov Pavel Alekseevich

panilovp.a@bmstu.ru

Martynov Nikolay Dmitrievich

martynov@bmstu.ru

BMSTU, Moscow, Russia

Abstract. Improving the efficiency and reliability of thermal power plants (TPPs) is essential for modern energy systems. Cognitive modeling emerges as a powerful approach for analyzing complex interdependencies among technological parameters, identifying optimal solutions, and enhancing plant operations. This methodology facilitates resource optimization, mitigates environmental impacts, and reduces the risks of accidents and failures. This paper explores the practical application of cognitive modeling in TPPs, highlighting its potential for improving operational efficiency, integrating with modern management systems, and fostering sustainable energy production.

Keywords: cognitive modeling, thermal power plants, optimization, recommendation systems, resource efficiency

Введение. Тепловые электростанции (ТЭС) играют центральную роль в глобальной выработке электроэнергии, оказывая решающее влияние на удовлетворение энергетических потребностей современных экономик. Несмотря на их жизненно важное значение, ТЭС сталкиваются с серьезными вызовами, которые препятствуют их эффективности, надежности и устойчивости. Эти вызовы включают устаревшую инфраструктуру, рост спроса на энергию, жесткие экологические нормативы и чрезмерную зависимость от устаревших технологий. В результате ТЭС испытывают трудности с поддержанием оптимальной производительности, что приводит к снижению эффективности, операционным рискам и увеличению затрат. Для решения этих проблем и обеспечения долгосрочной работы ТЭС необходимо внедрение инновационных подходов, направленных на повышение эксплуатационной эффективности [1].

С течением времени были разработаны различные методы оптимизации, предназначенные для решения сложных проблем, с которыми сталкиваются ТЭС. Эти методы варьируются от традиционного математического моделирования до передовых алгоритмов машинного обучения (ML), каждый из которых обладает своими преимуществами, но также имеет присущие ему ограничения. Согласно Смиту и др., математическое моделирование и симуляция обеспечивают теоретическую основу для понимания динамики систем ТЭС. Эти подходы позволяют проводить анализ сценариев, оптимизацию проектных решений и прогнозирование производительности станции [2]. Однако они зачастую опираются на упрощающие предположения, которые не отражают всей сложности реальных эксплуатационных условий. Как отмечают Браун и Харрис, такие модели игнорируют взаимозависимости между различными компонентами станции и не способны адаптироваться к динамическим и непредвиденным условиям.

Появление методов машинного обучения (ML) и искусственного интеллекта (AI) открыло новые возможности для оптимизации работы ТЭС. Эти передовые технологии используют большие массивы данных для выявления скрытых закономерностей, прогнозирования поведения системы и реализации оперативных корректировок. Ли и др. продемонстрировали, что алгоритмы машинного обучения особенно хорошо подходят для управления нелинейными зависимостями, характерными для процессов на ТЭС, что делает их идеальными для таких приложений, как предиктивное обслуживание и оптимизация процессов [3]. Однако существуют препятствия для широкого внедрения этих технологий. Чен и др. обсуждают высокие вычислительные затраты, сложности интеграции с устаревшими системами, а также необходимость в больших объемах качественных обучающих данных, что затрудняет их практическое применение в ТЭС.

Несмотря на достижения в области методов оптимизации, их ограничения подчеркивают необходимость более целостных и адаптивных подходов, способных учитывать сложную и взаимосвязанную природу современных ТЭС. Когнитивное моделирование стало перспективным решением, объеди-

няющим преимущества традиционных математических моделей, систем управления и искусственного интеллекта для создания более гибкой и устойчивой структуры, обеспечивающей оптимизацию работы в реальном времени. Согласно Гринвуду и Джексону, этот подход имитирует когнитивные процессы человека, что способствует повышенной адаптивности и принятию решений в условиях неопределенности [4]. Учитывая взаимозависимости между операционными параметрами, когнитивное моделирование обеспечивает более глубокое понимание работы станции, позволяя получать предсказательные инсайты и динамическую оптимизацию.

Кроме того, Чжан и др. отмечают, что интеграция рекомендательных систем в когнитивные модели улучшает процесс принятия решений, предоставляя операторам практические рекомендации, помогающие справляться с конкретными вызовами и повышать общую эффективность работы станции. Потенциал когнитивного моделирования в оптимизации ТЭС привлекает все больше внимания в современных исследованиях. Юань и др. продемонстрировали его эффективность в снижении расхода топлива, уменьшении выбросов и повышении общей производительности станции [5]. Дополнительно исследуются гибридные системы, сочетающие когнитивное моделирование и машинное обучение, позволяющие решать динамические и нелинейные задачи, характерные для современных ТЭС. Ван и Ли подчеркивают, что эти достижения подтверждают возрастающую роль когнитивного моделирования как инструмента, соединяющего традиционные методы оптимизации и решения на основе ИИ, предлагая более адаптивный, эффективный и устойчивый подход к управлению ТЭС.

Материалы и методы. Когнитивное моделирование использует передовые методы анализа данных и алгоритмические подходы для имитации и повышения операционной эффективности тепловых электростанций (ТЭС). Исследуя сложные взаимосвязи между ключевыми операционными параметрами, такими как температура, распределение нагрузки и расход топлива, эти модели способствуют оптимизации работы станции и поддержке решений, основанных на данных [6, 7].

Благодаря имитации сложных взаимодействий в пределах станции и постоянному анализу больших объемов данных, когнитивные модели способствуют принятию более обоснованных решений, повышению эффективности системы и достижению устойчивости.

Основные преимущества:

Оптимизация ресурсов: Когнитивные системы позволяют выявлять наиболее эффективные способы использования ресурсов, таких как топливо и вода, что снижает эксплуатационные затраты и минимизирует воздействие станции на окружающую среду.

Предиктивное обслуживание: Когнитивные модели способны прогнозировать потенциальные отказы оборудования или снижение его производительности, что позволяет проводить профилактические меры, уменьшая риски и повышая надежность станции.

Поддержка обучения персонала: Эти системы помогают операторам лучше понимать сложные процессы внутри станции, повышая их квалификацию и улучшая качество принимаемых решений.

Интеграция с системами автоматизации: Когнитивное моделирование легко интегрируется с системами управления и автоматизации в реальном времени, что позволяет станции динамически адаптировать свою работу на основе оперативных данных и прогнозов.

Архитектура рекомендательной системы для оптимизации работы ТЭС состоит из нескольких взаимосвязанных слоев, работающих совместно для улучшения процесса принятия решений и повышения эффективности станции (рис. 1).



Рис. 1. Архитектура системы

В основе входного слоя находятся несколько источников данных, которые обеспечивают систему как оперативной, так и исторической информацией, необходимой для оптимального принятия решений.

Сбор данных: Этот компонент собирает данные с датчиков, которые контролируют ключевые параметры работы, такие как температура, давление, распределение нагрузки, расход топлива и экологические показатели. Благодаря непрерывному сбору этих данных система может оперативно реагировать на изменяющиеся условия в реальном времени [8].

Хранилище исторических данных: В этом хранилище сохраняются данные о предыдущих операциях, что позволяет анализировать тенденции и сравнивать их с текущими условиями работы. Этот исторический контекст помогает принимать более обоснованные решения, поддерживая предсказательные возможности системы.

Внешние факторы: Включает данные из внешних источников, такие как погодные условия, сезонные колебания и спрос на электроэнергию в сети. Эти факторы могут существенно повлиять на работу станции, и их интеграция в модель позволяет учитывать все переменные, влияющие на производительность.

После сбора данные проходят несколько этапов обработки, подготавливая их для анализа и принятия решений.

Модуль предварительной обработки данных: В этом модуле необработанные данные из различных источников очищаются, фильтруются и нормализуются. Это гарантирует, что информация, поступающая в систему, является точной, согласованной и готовой для углубленного анализа.

Анализ корреляций и зависимостей: Этот компонент исследует взаимосвязи между различными операционными параметрами, например, как температура окружающей среды влияет на расход топлива или как распределение нагрузки сказывается на эффективности работы станции. Понимание этих взаимозависимостей позволяет системе принимать более обоснованные решения [9].

Алгоритмы оптимизации: Для выявления оптимальных конфигураций работы станции применяются модели машинного обучения и эволюционные алгоритмы. Эти алгоритмы обрабатывают большие объемы данных, предлагая наилучшие условия эксплуатации и прогнозируя результаты различных стратегий.

После обработки данных система рекомендаций генерирует практические выводы, которые направляют работу станции. Она включает два ключевых компонента:

Механизм рекомендаций: На основе обработанных данных и результатов работы оптимизационных алгоритмов механизм рекомендаций предлагает наиболее эффективные стратегии эксплуатации станции. Например, он может рекомендовать оптимальную температуру работы для повышения топливной эффективности или идеальное распределение нагрузки для снижения нагрузки на турбины [10, 11].

Модуль анализа сценариев: Этот модуль моделирует различные эксплуатационные сценарии в разных условиях, помогая оценивать потенциальные результаты различных стратегий. Оценивая множество возможных исходов, система выбирает наиболее устойчивый и эффективный подход.

Заключительный слой переводит рекомендации в конкретные действия, которые могут быть внедрены на станции.

Интеграция с системой управления: Оптимизированные параметры, сгенерированные системой рекомендаций, напрямую интегрируются в системы управления станции. Это позволяет в реальном времени корректировать эксплуатационные параметры, обеспечивая оптимальную работу на основе актуальных рекомендаций.

Панель управления для операторов: Панель управления выступает в качестве пользовательского интерфейса, предоставляя операторам визуализа-

ции рекомендуемых параметров, ключевых метрик производительности и предсказательной аналитики. Это помогает операторам принимать обоснованные решения и контролировать работу станции в реальном времени.

Цикл обратной связи: Система непрерывно собирает данные об изменениях в производительности в реальном времени. Этот цикл обратной связи позволяет системе уточнять будущие рекомендации, улучшая точность и эффективность оптимизации с течением времени.

Интеграция когнитивного моделирования в управление тепловыми электростанциями обеспечивает комплексное решение для оптимизации производительности, повышения качества принимаемых решений, а также поддержки предсказательного обслуживания и обучения операторов.

Результаты. Когнитивные рекомендательные системы способны прогнозировать и оптимизировать ключевые технические показатели, напрямую влияющие на эффективность ТЭС. Используя предсказательную аналитику и потоки оперативных данных, они предсказывают эксплуатационные показатели, что способствует более рациональному использованию ресурсов. Например, механизм рекомендаций может предлагать оптимальное распределение нагрузки между турбинами на основе прогнозируемого расхода топлива, что помогает снизить износ оборудования и одновременно максимизировать выработку энергии.

Рекомендательная система формирует мощную базу знаний, анализируя эксплуатационную историю, состояние оборудования и поступающие данные с датчиков. В процессе обработки информации система выявляет закономерности, например, влияние колебаний температуры или типа топлива на производительность станции. Такой глубокий анализ данных не только помогает в оперативном принятии решений, но и способствует долгосрочной стратегии оптимизации работы ТЭС.

Предсказательное техническое обслуживание является ключевым аспектом когнитивного моделирования для ТЭС. Система непрерывно отслеживает состояние оборудования и анализирует данные о его работе, чтобы прогнозировать возможные отказы или признаки износа. Используя эти сведения, система может автоматизировать процесс планирования технического обслуживания, сводя к минимуму внеплановые простои, снижая затраты на ремонт и продлевая срок службы критически важных узлов оборудования. Компонент «Планирование технического обслуживания» в блоке рекомендаций интегрирует эти данные для формирования наиболее эффективного графика ремонтных работ.

Оперативный мониторинг играет решающую роль в обеспечении эффективности работы ТЭС, а рекомендательная система предоставляет непрерывные и практические аналитические данные. Система способна выявлять отклонения от оптимальных параметров и предлагать корректирующие меры в режиме реального времени. Например, если температура выходит за пределы допустимого диапазона, система может порекомендовать скорректировать подачу топлива или параметры охлаждения. Такой динамический процесс

обеспечивает максимальную эффективность работы станции даже в условиях изменяющихся внешних или эксплуатационных факторов.

Обсуждение. Рекомендательная система тесно интегрирована с инструментами мониторинга электростанции, такими как SCADA и диагностические системы. Эта интеграция позволяет системе получать полные и актуальные эксплуатационные данные, что повышает точность рекомендаций. Используя эти данные, механизм рекомендаций совершенствует алгоритмы принятия решений, гарантируя, что все аспекты работы станции остаются в оптимальном состоянии.

Рекомендательная система на тепловой электростанции следует логическому процессу — от сбора данных до выработки практических решений (рис. 2).

Рекомендательная система состоит из следующих модулей:

Входной уровень: Сбор оперативных данных и исторических трендов из различных источников, включая датчики и внешние экологические факторы.

Анализ данных: Обработка информации для оценки ее влияния на производительность.

Алгоритмы оптимизации: На основе полученных аналитических данных система рассчитывает оптимальные стратегии работы, включая распределение ресурсов, балансировку нагрузки и графики технического обслуживания.

Модель рекомендаций: Система формирует практические рекомендации по повышению эффективности работы станции.

Планирование технического обслуживания и корректировка параметров: Осуществляется предсказательное техническое обслуживание и оперативные корректировки работы станции в реальном времени.

Панель управления оператора: Все рекомендации и корректировки отображаются на панели оператора для удобного внедрения и мониторинга в реальном времени.




Рис. 2. Рекомендательная система

Этот процесс обеспечивает непрерывную оптимизацию и предсказательное техническое обслуживание, способствуя повышению эффективности работы станции и снижению времени простоя.

Объединяя когнитивное моделирование с предсказательной аналитикой и оперативным принятием решений, рекомендательная система для ТЭС становится мощным инструментом для максимизации эффективности, снижения затрат и обеспечения стабильной работы в долгосрочной перспективе.

Заключение. Интеграция когнитивного моделирования с рекомендательными системами представляет собой целостный подход к оптимизации работы ТЭС. Рекомендательная система, использующая как данные в реальном времени, так и исторические тренды, помогает эффективно управлять ресурсами, предсказывать потребности в обслуживании и быстро адаптироваться к изменениям в операционных условиях. Это позволяет минимизировать необходимость в ручных корректировках, снизить простои оборудования и значительно повысить общую эффективность работы станции, обеспечивая тем самым устойчивость производственных процессов.

Также благодаря интеграции когнитивных систем с существующими технологиями автоматизации, такими как SCADA-системы и средства мониторинга, тепловые электростанции становятся более гибкими и способны оперативно реагировать на как предсказуемые, так и непредсказуемые изменения в условиях эксплуатации. Это не только способствует снижению эксплуатационных расходов, но и помогает сократить негативное воздействие на окружающую среду, оптимизируя использование ресурсов.

Список источников

- [1] Shilkin O.V., Kishkin A.A., Shevchenko Y.N. et al. Combined Two-Phase Thermal Control System with Parallel Capillary Pumps. *Chem Petrol Eng.*, 2021, vol. 57, pp. 311–316. <https://doi.org/10.1007/s10556-021-00935-8>
- [2] Zarubin V.S., Zimin V.N., Kuvyrkin G.N. et al. Influence of thermal conducting inclusions on the limiting potential difference of polymer composite electrical insulation. *Polym. Bull.*, 2023, vol. 80, pp. 5573–5585. <https://doi.org/10.1007/s00289-022-04315-x>
- [3] Cansu T., Kolemen E., Karahasan Ö. et al. A new training algorithm for long short-term memory artificial neural network based on particle swarm optimization. *Granul. Comput.*, 2023, vol. 8, pp. 1645–1658. <https://doi.org/10.1007/s41066-023-00389-8>
- [4] Wang Q., Pan L., Lee K.Y. et al. Deep-learning modeling and control optimization framework for intelligent thermal power plants: a practice on superheated steam temperature. *Korean J. Chem. Eng.*, 2021, vol. 38, pp. 1983–2002. <https://doi.org/10.1007/s11814-021-0865-6>
- [5] Arutyunyan R.V. Simulation of Thermal and Electric Fields in Electrodes with Allowance for Melting and Fritting of Films. *J Eng Phys Thermophy*, 2022, vol. 95, pp. 636–641. <https://doi.org/10.1007/s10891-022-02519-6>
- [6] Панилов П.А., Цибизова Т.Ю., Воскресенский Г.А. Методология экспертно-агентного когнитивного моделирования предупреждения воздействия на критическую информационную инфраструктуру. *Ключевые тренды развития искусственного интеллекта: наука и технологии. Междунар. ИТ-конф.: сб. тр.* Москва, Изд-во МГТУ им. Н.Э. Баумана, 2023, с. 98–104.

- [7] Pupkov K.A., Brovarkaya Y.K. Dynamic and Information Properties of Intelligent Control Systems. *Procedia Computer Science*, 2021, vol. 186, pp. 489–494.
- [8] Webb S.D. SOAR — the solution to the high prevalence of heart disease in Appalachian Kentucky. *J Public Health (Berl.)*, 2021, vol. 29, pp. 1331–1338. <https://doi.org/10.1007/s10389-020-01248-5>
- [9] Toshev A., Talanov M. Artificial Cognitive Architectures Review. *BioNanoSci.*, 2020, vol. 10, pp. 811–823. <https://doi.org/10.1007/s12668-020-00768-4>
- [10] Ghahramani Z. Probabilistic machine learning and artificial intelligence. *Nature*, 2015, vol. 521, pp. 452–459. <https://doi.org/10.1038/nature14541>
- [11] LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436–444. <https://doi.org/10.1038/nature14539>