
Использование алгоритмов машинного обучения для системы солнечного теплоснабжения

М.М. Кунелбаев

Институт информационных и вычислительных технологии МОН РК, Алматы, Казахстан

Аннотация: В этой статье исследуется использование алгоритмов машинного обучения для выявления аномалий в системе солнечного отопления. Разработанная система солнечного отопления состоит из нескольких частей для упрощения процесса описания и моделирования. Автор предлагает новую архитектуру нейронных сетей, основанную на обыкновенных дифференциальных уравнениях. Идея состоит в том, чтобы применить новую архитектуру для практических задач прогнозирования аварий (проблема экстраполяции временных рядов) и классификации (классификация аварий на основе исторических данных). Разработанные алгоритмы машинного обучения, методы искусственного интеллекта, теория дифференциальных уравнений - эти направления позволяют нам построить модель для прогнозирования аварийности системы. Теория управления базами данных (нереляционными базами данных) - эти системы позволяют установить оптимальное хранение больших временных рядов.

Ключевые слова: плоский солнечный коллектор, система солнечного отопления, машинное обучение, алгоритм/

Введение

В статье [1] рассматривалось, как повысить производительность и надежность систем возобновляемой энергетики для снижения связанных с этим инвестиционных и эксплуатационных затрат. В работе [2] исследовалось несколько приложений машинного обучения (ML) в программе прогнозирования и управления здоровьем (PHM), направленных на повышение доступности и производительности сложных систем. В статье используются методы глубокого обучения (DL) для разработки системы в литий-ионных батареях [3] и других. Солнечные системы горячего водоснабжения (ГВС) являются коммерчески зрелыми приложениями солнечной тепловой технологии для жилых и низкотемпературных промышленных применений.

В статье [4] были разработаны прогнозы производительности плоских солнечных коллекторов для оценки работоспособности системы и



оказания помощи в выполнении задач планирования технического обслуживания. В статье [5] использовались различные версии искусственных нейронных сетей. Прогнозирование производительности и анализ эффективности при различных метеорологических условиях изучаются в системах SHW, системах солнечных тепловых насосов и системах хранения тепла с использованием различных моделей нейронных сетей, таких, как многослойный персептрон (MLP), радиальные базисные функции (RBF) и адаптивный вывод системы на основе нечетких сетей (ANFIS). В работе [6] была разработана система диагностики неисправностей, в которой отслеживаемые данные сравниваются с прогнозируемыми значениями, что позволяет обнаруживать неисправности в солнечных коллекторах с хорошими результатами [6]. В статье [7] исследование проведено с помощью памяти (LSTM-RNN), реализованной для анализа долгосрочных временных зависимостей. В работе [8] исследование нейронных сетей LSTM для прогнозирования глобальной горизонтальной освещенности на предстоящий день сравнивалось со спутниковыми данными. В статье [9] разработаны средства управления с электрическими сетями для определения размеров системы хранения возобновляемой энергии. В статье [10] были разработаны архитектуры ANN, RNN и LSTM для прогнозирования температуры в системе SHW; и проведено сравнение в аналогичных условиях, чтобы выделить их сильные и слабые стороны. Путем сравнения ошибок прогнозирования модели, сгенерированной с использованием номинальных данных, и данных, вызванных ошибками, определяется пороговое значение на основе ошибок для классификации состояния работоспособности системы. В статье [11] исследовались синтетические данные, которые генерируются в TRNSYS при номинальных условиях и условиях, вызванных аномалиями. При моделировании TRNSYS

использовались оценки производителя, включая расчетные температуры, размеры и мощности оборудования, а также схему управления для каждой подсистемы. В статье [12] представлено исследование, которое объединяет подходящую искусственную нейронную сеть (ANN) и TRNSYS для прогнозирования производительности прототипа интегрированного хранилища коллекторов (ICS).

Методика исследования

Прогнозирование аварийности и стабильной работы технических устройств – актуальная задача в различных областях. Прогноз необходимо делать заранее, чтобы обеспечить качественную работу устройств. Логично, что эта проблема экономически эффективна по сравнению с проблемой полной замены или капитального ремонта конкретного технического устройства. Определение аварийности может быть основано на понимании того, как работают основные компоненты устройства. В том случае, если все компоненты работают исправно, производительность лучше, и, следовательно, меньше шансов аварийной ситуации. Современные исследования показали, что непрерывный мониторинг и анализ компонентов остается наиболее важной задачей для многих компаний. Выявление предаварийности технического устройства основывается на предсказании аварийности его основных компонентов, которые оказывают огромное влияние на рабочие характеристики оборудования.

В настоящее время единственный практический способ контролировать состояние таких компонентов – это обнаруживать сложные сигналы, такие, как вибрация, давление и электрический ток, генерируемые техническими устройствами и собранные промышленными датчиками.

Предложен алгоритм машинного обучения для задачи регрессии и временного ряда. Когда модель выявила отклонение между обученной регрессионной моделью и фактическим значением, сопоставили аномальное поведение технического устройства. LightGBM используется для построения регрессионной модели, результаты модели по метрике RSME составляют около 1 %.

Авторы предлагают новую архитектуру нейронных сетей на основе обыкновенных дифференциальных уравнений. Идея заключается в применении новой архитектуры для практических задач предсказания аварийности (проблема экстраполяции временных рядов) и классификации (классификация аварийности на основе исторических данных).

Применение новой архитектуры имеет ряд преимуществ по сравнению с существующими архитектурами RNN, таких, как:

1) Эффективность. В обучении нейронных дифференциальных уравнений необязательно вычислять градиент через все операции численного метода, и также нет необходимости хранить промежуточные результаты.

2) Гибкость времени работы. По сравнению с решениями дифференциальных уравнений, где шаг сетки определяет точность модели и влияет на время вычисления, в нейронных дифференциальных уравнениях мы можем явно контролировать баланс между численной точностью и вычислительными затратами.

3) Количество параметров. Если сравнивать с ResNet, преимуществом предложенной архитектуры является меньшее количество параметров, так как для каждого слоя не требуется новых параметров.

Результаты исследования

Для предсказания временных рядов в основном используют рекуррентную нейронную сеть (RNN). Принцип работы RNN заключается в следующем: обучающая выборка подается на вход RNN (кодировщик), результатом будет нормальное распределение, на основе которого генерируется случайная величина $z(t_0) \sim q(z(t_0) | \mu, \sigma)$, где μ, σ – математическое ожидание и стандартное отклонение нормального распределения. Затем $z(t_0)$ подается на вход другой RNN (декодировщик), которая восстанавливает значения по тестовым данным. Данная нейронная сеть использует дискретные преобразования $z(t+1) = z(t) + f(z(t), t)$, где $f(z(t), t)$ – некоторое нелинейное преобразование, совпадающее со схемой ОДУ методов Эйлера. Фактически можно изменить направление от дискретного преобразования в непрерывные траектории $z(t)$. Эта замена позволяет создать новую архитектуру нейросетевых ОДУ.

На рис. 1 показана схема работы нейросетевых ОДУ и ее отличие от RNN.

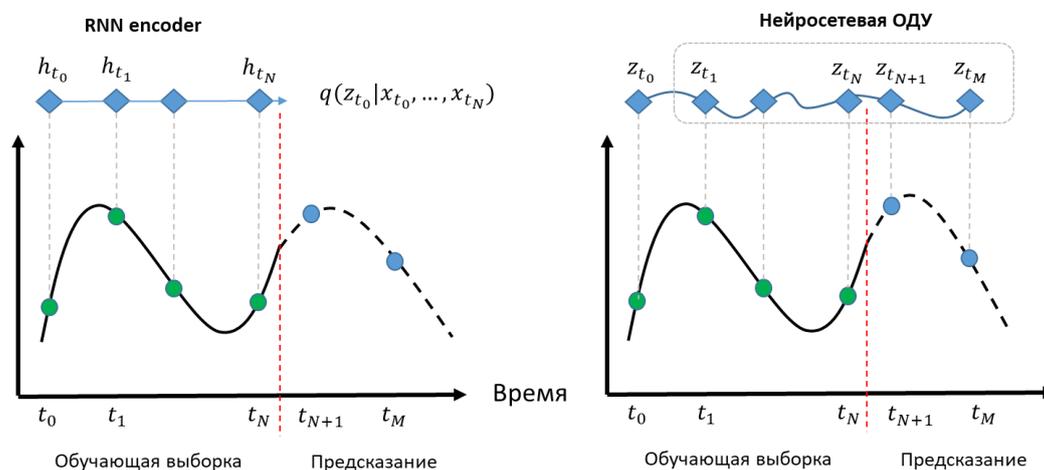


Рис. 1. - Схема работы RNN и нейросетевых ОДУ

Для проведения верификации выбрали плоский гелиоколлектор, данные были собраны за три месяца наблюдения с технических устройств. Были установлены датчики температуры в бак аккумулятора, на выходе из плоского гелиоколлектора, а датчики напряжения – на насосе и вибрации.

На основе полученных данных можно предсказывать будущие проблемы в установке, такие, как поломка насоса, разгерметизация и др.

Дополнительно были собраны данные об окружающей среде за один год. На рис.2 показана высокая корреляция между солнечным излучением и температурой в коллекторе и резервуаре. Если плотность солнечного излучения выше, то температура является более монотонной, а стандартное отклонение температуры в хранилище близко к среднему значению, например, с июля по август.

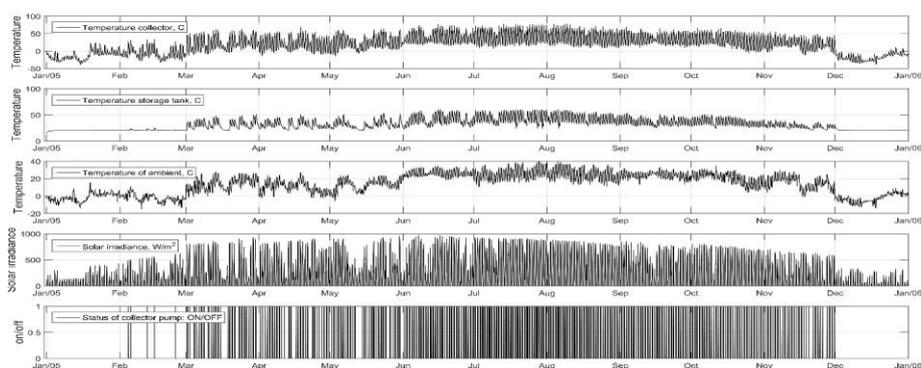


Рис. 2. - Результат моделирования со сравнением температуры окружающей среды и солнечной освещенности

На рис.3 показаны температуры в коллекторе, резервуаре и режиме работы насоса. Видим корреляцию между температурой окружающей среды и температурой нагреваемой воды. Когда температура в коллекторе достигает 40°C , насос переключается и начинает передавать нагретую жидкость в теплообменник внутри накопительного резервуара и получает охлажденную жидкость в цикле коллектора для нагрева. Вторая причина охлаждения жидкости в цикле связана с погодными условиями (снижение температуры окружающей среды, закат).

Для оценки точности обучали модель на исторических данных для улавливания сезонности и тренда временного ряда. Предсказание модели было выполнено за последний месяц. Для оценки точности модели использовалась метрика RSME.

Верификация рассмотренной модели показала хорошие результаты в предсказании будущего поведения нагрузки насоса.

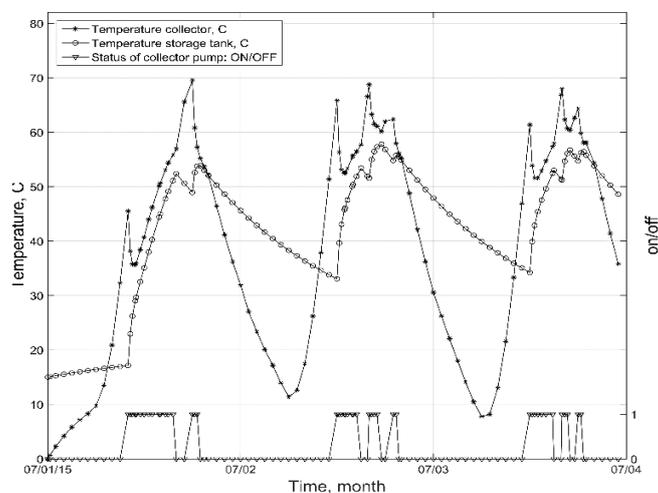


Рис. 3. - Температура окружающей среды и температура в коллекторе и резервуаре с режимом работы насоса

На рис. 4 можно заметить, что модель предсказала будущую температуру воды из контура – больших отклонений не наблюдается.

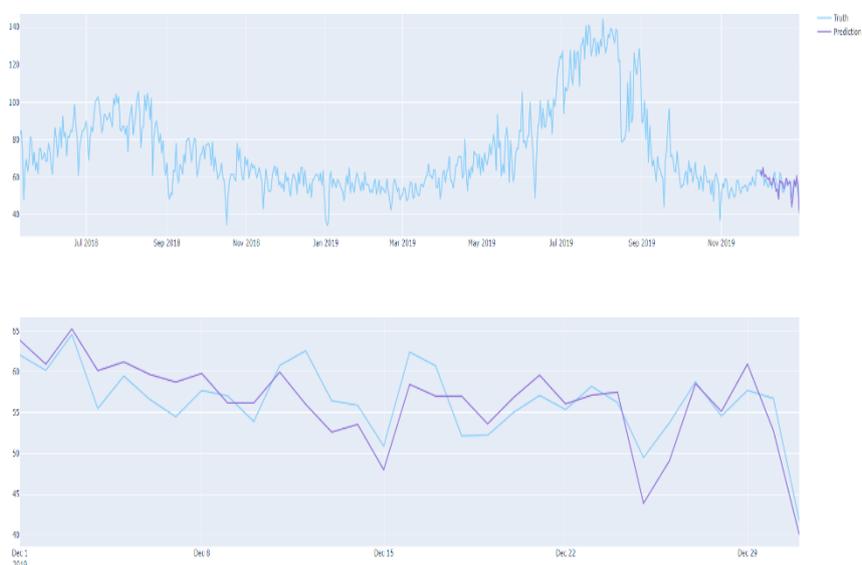


Рис.4. - Предсказание температуры в контуре гелиоколлектора

На рис. 5 показаны предсказания температуры в контуре гелиоколлектора. Мы можем наблюдать разницу между предсказанной температурой в модели и фактической. Это может быть сигналом того, что

наблюдаются отклонения от нормативных показателей температуры в системе. Модель подсказывает, что необходимо провести осмотр установки.

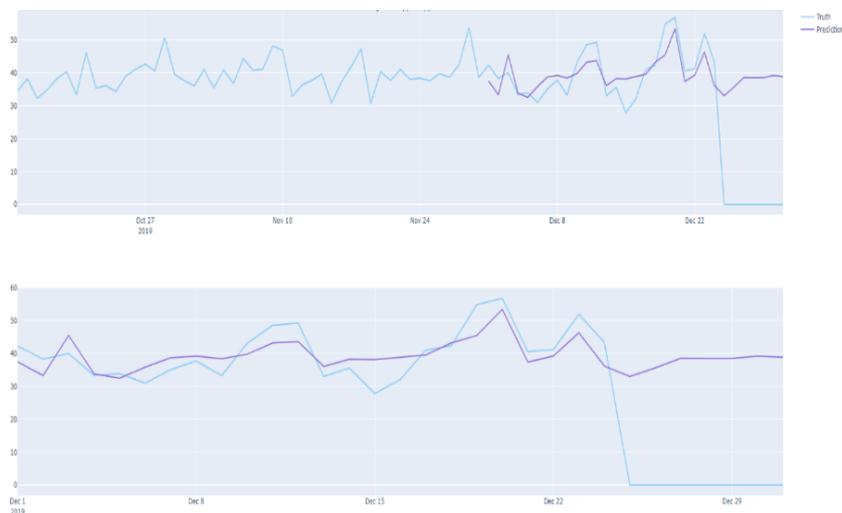


Рис. 5. -Аномальное отклонение показателей температуры в баке аккумулятора

Модель также выявляла аномальные отклонения в показаниях давления (бар) в контуре установки. На рис.6 можно заметить большие отклонения между предсказанными значениями и оригинальными показаниями с датчиков.

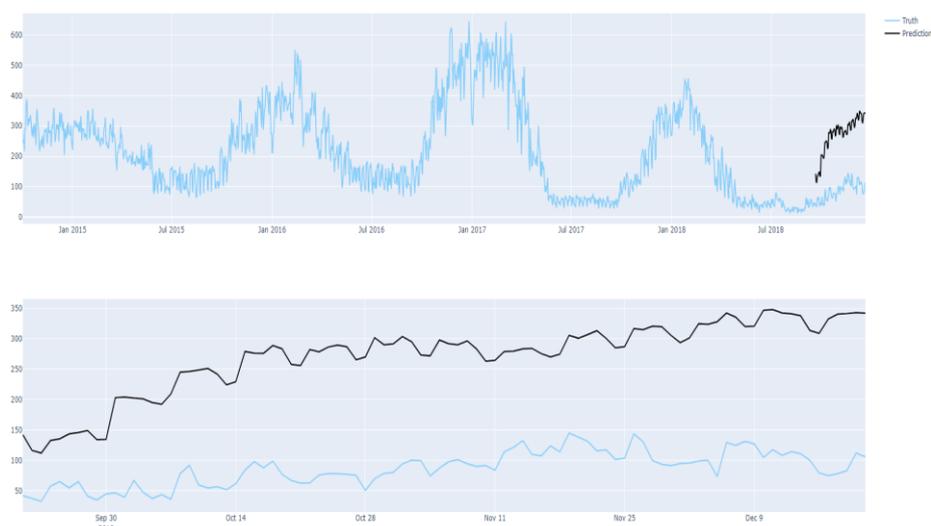


Рис.6. - Аномальные отклонения в показаниях атмосферного давления в установке

Созданная модель была смоделирована полностью солнечной системой горячего водоснабжения: плоский коллектор, накопительный бак и насосы. На основе математической модели солнечного плоского коллектора была разработана блок-схема Симулинка, блочная схема модели коллектора. Результатом моделирования является температура жидкости на выходе из коллектора.

Заключение

Созданная модель была полностью смоделирована для системы солнечного отопления. На основе математической модели солнечного плоского коллектора была разработана структурная схема модели коллектора. Результатом моделирования является температура жидкости, выходящей из резервуара. Для проверки был выбран плоский солнечный коллектор; данные были собраны за 3 месяца наблюдений с технических устройств. Датчики температуры были установлены в аккумуляторном баке, на выходе из плоского солнечного коллектора, датчики напряжения - на насосе и вибрации. Основываясь на данных датчиков температуры и давления, мы можем предсказать будущие проблемы в установке, такие, как поломка насоса, разгерметизация и многое другое. Наблюдалась разница между прогнозируемой температурой в модели и фактической температурой. Это может быть сигналом о том, что в системе имеются отклонения от стандартных показателей температуры. Модель предложит вам проверить установку. Модель также показала аномальные отклонения в показаниях давления (бар) в контуре блока. Кроме того, вы можете заметить большие отклонения между прогнозируемыми значениями и исходными показаниями датчиков.



Литература (References)

1. RENA, Opportunities to accelerate national energy transitions through advanced deployment of renewable. 2018. URL: irena.org/publications/2018/Nov/Opportunities-to-accelerate-national-energy-transitions-through-advanced-deployment-of-renewables.
2. Niu G. Data-Driven Technology for Engineering Systems Health Management. Springer Singapore. Singapore.2017. P.357.
3. Lui Y., Zhao G., Peng X., Hu C. Annu. Conf. Progn.Heal.Manag.Soc.2017.№9 (3). pp.1–7.
4. de Keizer A.C., Vajen K., Jordan U. Sol. Energy.2018. №85. pp.1430–1439.
5. Ghritlahre H.K., Prasad R.K. A review. Renew. Sustain. Energy Rev.2018.№84. pp.75–88.
6. Kalogirou S., Lalot S., Florides G., Desme B. Sol. Energy.2008.№ 82. pp. 164–172.
7. Lipton Z.C., Berkowitz J., Elkan C. Proc. ACM Int. Conf. Multimed. MM '14.2015. pp.675–678.
8. Srivastava S., Lessmann S. Sol. Energy.2018.№ 162. pp.232–247.
9. Leva S., Dolara A., Grimaccia F., Mussetta M., Ogliari E. Math. Comput. Simul.2017. №131.P.88–100.
10. Correa-Jullian C., Cardemil J.M., Droguett E.L., Behzad M. Renew. Energy.2019.№145.pp.2178–2191.
11. Kalogirou S.A., Agathokleous R., Barone G., Buonomano A., Forzano C., Palombo A. Renew. Energy.2019.№136. pp.632–644.
12. Souliotis M., Kalogirou S., Tripanagnostopoulos Y. Renew. Energy.2009.№34. pp.1333–1339.