

Панченко Вероника Юрьевна

магистрант

ФГБОУ ВО «Сибирский государственный университет
науки и технологий им. академика М.Ф. Решетнева»

г. Красноярск, Красноярский край

АДАПТИВНОЕ УПРАВЛЕНИЕ ЭНЕРГОПОТРЕБЛЕНИЕМ В РЕАЛЬНОМ ВРЕМЕНИ НА ОСНОВЕ ПОТОКОВЫХ МОДЕЛЕЙ ОНЛАЙН-ОБУЧЕНИЯ

Аннотация: рассмотрен подход к адаптивному энергоменеджменту на базе потоковых моделей машинного обучения с детекцией концептуального дрейфа. Инкрементальные алгоритмы обновляются по мере поступления телеметрии; детектор ADWIN автоматически инициирует адаптацию весов. Показано, что онлайн-подход снижает ошибку (MAE) на 29% по сравнению с пакетным переобучением при задержке обновления менее 2 мс.

Ключевые слова: адаптивное энергопотребление, онлайн-обучение, концептуальный дрейф, инкрементальные модели, умные здания.

Введение: статические модели прогнозирования энергопотребления теряют точность при нестационарных режимах, вызванных деградацией оборудования, сдвигами графиков и интеграцией распределённых энергоресурсов. Пакетное переобучение требует значительных вычислительных ресурсов и не обеспечивает реакцию в реальном времени. Потокковое обучение устраняет этот недостаток, обновляя веса последовательно по мере поступления данных, что критически важно для замкнутых контуров управления.

Методология: предложена архитектура, объединяющая однопроходную предобработку (алгоритм Уэлфорда, экспоненциальное сглаживание) и инкрементальные модели. Сопоставлены стохастический градиентный спуск (SGD), деревья Хаффдинга и адаптивный случайный лес (Adaptive Random Forest, ARF).

Для автоматического выявления смены распределения данных без заранее заданных порогов применяется детектор ADWIN, сжимающий адаптивное окно по неравенству Хеффдинга при обнаружении статистически значимого сдвига.

Результаты и обсуждение: эксперимент на реальной пятимесячной телеметрии (prequential-протокол) подтвердил преимущество ARF (табл. 1). Детектор зафиксировал 47 событий дрейфа со средней задержкой 12,3 наблюдения (~2 ч). Коэффициент детерминации составил $R^2 = 0,96$, задержка корректировки весов не превысила 2 мс, что подтверждает готовность к развертыванию на периферийных EMS-контроллерах с ограниченными ресурсами.

Таблица 1

Сравнение моделей потокового прогнозирования

Модель	MAE, Вт·ч	Реакция на дрейф
Batch Linear Regression	48,6	требует переобучения
SGDRegressor	41,2	~45 шагов
Hoeffding Tree	38,5	~25 шагов
Adaptive Random Forest	34,5	~18 шагов

Представленные в таблице 1 результаты сравнения четырёх подходов к потоковому прогнозированию энергопотребления выявляют чёткую закономерность: переход от пакетных методов к инкрементальным ансамблям обеспечивает систематическое снижение ошибки прогнозирования при одновременном ускорении адаптации к смене режимов.

Пакетная линейная регрессия демонстрирует наихудшие показатели – средняя абсолютная ошибка составляет 48,6 Вт·ч. Принципиальным ограничением данного метода является не столько величина ошибки, сколько невозможность адаптации без полного переобучения. В условиях, когда режимы потребления меняются несколько раз в сутки, это делает метод практически неприменимым для замкнутых контуров управления: каждая смена режима потребовала бы остановки системы, накопления нового датасета и повторного запуска тренировочного цикла.

Стохастический градиентный спуск снижает ошибку до 41,2 Вт·ч (на 15,2% относительно пакетной регрессии), однако скорость адаптации остаётся недостаточной – порядка 45 шагов для выхода на установившийся режим. При частоте дискретизации телеметрии в несколько минут это означает, что после каждой смены режима модель работает с повышенной ошибкой в течение нескольких часов, что критично для задач управления пиковыми нагрузками.

Дерево Хаффдинга обеспечивает дальнейшее снижение ошибки до 38,5 Вт·ч при скорости адаптации порядка 25 шагов. Преимущество данного метода заключается в использовании статистических границ для инкрементального разбиения узлов, что позволяет обходиться ограниченной памятью. Однако одиночное дерево лишено механизма оценки собственной деградации, что делает его уязвимым к кумулятивному дрейфу на длительных горизонтах.

Адаптивный случайный лес достигает наилучших результатов по обоим показателям: ошибка снижается до 34,5 Вт·ч (на 29,0% относительно пакетной регрессии и на 16,3% относительно дерева Хаффдинга), а скорость адаптации составляет порядка 18 шагов. Ключевое преимущество ансамблевой архитектуры состоит в механизме индивидуальной оценки точности каждого дерева: деградировавшие компоненты заменяются без реконструкции всей модели, что обеспечивает встроенную устойчивость к концептуальному дрейфу. Именно это свойство делает метод пригодным для развёртывания на периферийных контроллерах, где вычислительные ресурсы ограничены, а полный цикл переобучения невозможен без прерывания контура управления.

Сопоставление скорости адаптации и величины ошибки показывает, что эти параметры не являются независимыми: методы, обеспечивающие более быструю реакцию на дрейф, одновременно демонстрируют и более низкую установившуюся ошибку. Данная корреляция объясняется тем, что быстрая адаптация минимизирует период работы модели в условиях несоответствия параметров актуальному распределению данных, что снижает кумулятивную ошибку на всём горизонте наблюдения.

Практическая интерпретация результатов состоит в следующем: при задержке обновления весов менее 2 мс на шаг и скорости адаптации порядка 18 шагов адаптивный случайный лес обеспечивает переход в новый режим работы в течение 30–60 минут после фактической смены условий потребления, что является приемлемым для типовых контуров управления энергопотреблением зданий и промышленных предприятий.

Заключение: онлайн-обучение с детекцией дрейфа превращает систему энергоменеджмента в подлинно адаптивную. Предиктивное сглаживание пиков снижает плату за заявленную мощность и оптимизирует реакцию на динамические тарифы, выступая фактором социально-экономической устойчивости предприятия.

Список литературы

1. Клешко, И. И. Применение алгоритмов машинного обучения для выявления аномальных показаний датчиков карьерного водоотлива / И. И. Клешко, И. А. Вахрушева, Г. В. Кораблева // Известия Тульского государственного университета. Науки о Земле. – 2026. – № 3. – С. 235–248.

2. Правовые аспекты управления промышленными потоками данных в распределённых IoT-архитектурах / О. О. Олейникова, Е. С. Алмазова, Б. В. Потопов, Г. В. Кораблева // Стратегии устойчивого развития: социальные, экономические и юридические аспекты : материалы II Всероссийской научно-практической конференции (Чебоксары, 26 августа 2026 г.). – Чебоксары : Среда, 2026. – С. 390–393. – EDN OOLPWN.

3. Адаптивный энергоменеджмент на базе моделей онлайн-обучения как фактор социально-экономической эффективности предприятий / О. О. Олейникова, Д. А. Ткаченко, Г. В. Кораблева, А. С. Прудкий // Стратегии устойчивого развития: социальные, экономические и юридические аспекты : материалы II Всероссийской научно-практической конференции (Чебоксары, 26 августа 2026 г.). – Чебоксары : Среда, 2026. – С. 221–224. – EDN JGZIZE.

4. Кораблева, Г. В. Совершенствование процессов планирования на предприятиях за счёт внедрения автоматизированных систем поддержки принятия решений / Г. В. Кораблева // Ресурсосбережение. Эффективность. Развитие: сборник материалов IX Всероссийской научно-практической конференции (Донецк, 1 ноября 2024 г.). – Донецк : Донецкий национальный технический университет, 2024. – С. 63–65. – EDN WIOIYS.

5. Интерпретируемые модели машинного обучения в задачах оценки экологической и промышленной безопасности горнодобывающих предприятий / Л. А. Казаковцев, А. С. Прудкий, И. А. Вахрушева, А. Н. Лосев // Известия Тульского государственного университета. Науки о Земле. – 2026. – № 1. – С. 169–174. – EDN GNIXFD.

6. Интеллектуальная модель прогнозирования объемов образования отходов на основе методов машинного обучения / Т. А. Панфилова, В. С. Тынченко, Б. В. Потапов, М. С. Никаноров // Устойчивое развитие горных территорий. – 2026. – Т. 18, № 2 (68). – С. 1107–1120. – DOI 10.21177/1998-4502-2026-18-2-1107-1120. – EDN GTTEPG.