

Временно-метеорологическая адаптация моделей искусственного интеллекта для планирования режимов работы фотоэлектрических станций

П. В. Матренин

Аннотация— В статье представлен метод временно-метеорологической адаптации прогнозных моделей на основе машинного обучения для задач краткосрочного прогнозирования генерации электрической энергии. Метод основан на совместном использовании кластеризации входных данных и периодической адаптации моделей в процессе эксплуатации. Кластеризация позволяет выделять различные режимы функционирования объекта и обучать специализированные локальные модели, а временная адаптация обеспечивает компенсацию деградации качества прогнозирования, вызванной дрейфом данных. Для оценки эффективности предложенного подхода проведено экспериментальное исследование на задаче краткосрочного прогнозирования генерации фотоэлектрической станции. Использован многолетний массив почасовых метеорологических данных. Выполнено сравнение базового варианта прогнозирования с вариантами временной, метеорологической и совместной временно-метеорологической адаптации. Наилучшие результаты достигнуты при совместном использовании временной и метеорологической адаптации, что подтверждает эффективность учета как дрейфа данных, так и неоднородности метеорологических условий.

Ключевые слова— прогнозирование временных рядов, модели машинного обучения, адаптация, фотоэлектрическая станция, планирование режимов.

I. ВВЕДЕНИЕ

А. Методы прогнозирования генерации фотоэлектрических станций

Рост доли возобновляемых источников энергии (ВИЭ) является одной из ключевых тенденций развития современной электроэнергетики. Развитие солнечной и ветровой генерации рассматривается как важный фактор повышения энергетической безопасности, снижения углеродного следа и обеспечения устойчивого развития энергетических систем [1, 2]. Вместе с тем увеличение доли ВИЭ приводит к росту неопределенности режимов работы энергосистем из-за зависимости выработки электроэнергии от метеорологических факторов [3, 4].

Для фотоэлектрических станций (ФЭС) качество краткосрочного прогнозирования генерации имеет существенное значение при решении задач оперативно-диспетчерского управления, планирования режимов работы оборудования, управления накопителями энергии и обеспечения баланса мощности в энергосистемах [5, 6].

Существующие подходы к прогнозированию генерации электроэнергии на базе ВИЭ можно разделить на три группы: физико-математические метеорологические модели, статистические методы и методы искусственного интеллекта [3].

В задачах прогнозирования выработки ФЭС классические авторегрессионные методы и методы анализа временных рядов обладают ограниченной эффективностью вследствие высокой нестационарности и нелинейности процессов солнечной генерации. Выработка ФЭС существенно зависит от метеорологических факторов – инсоляции, облачности, температуры и влажности воздуха, что приводит к изменению статистических характеристик временных рядов во времени. Кроме того, указанные методы преимущественно ориентированы на анализ внутренней структуры временного ряда и недостаточно эффективно учитывают многомерные внешние факторы.

В связи с этим в последние годы наблюдается переход от классических методов анализа временных рядов к моделям машинного обучения, способным учитывать большое число взаимосвязанных факторов, включая ансамбли деревьев решений, искусственные нейронные сети и гибридные методы прогнозирования [4, 7–10]. Результаты исследований показывают, что такие модели способны обеспечивать высокую точность прогнозов при наличии достаточного объема исторических данных и качественной информации о метеорологических условиях [3, 4, 8, 9].

Однако большинство существующих моделей строится в предположении стационарности данных и предполагает однократное обучение на фиксированной исторической выборке. В реальных условиях эксплуатации статистические характеристики входных данных изменяются во времени вследствие сезонных и климатических изменений, модернизации оборудования, изменения режимов функционирования энергетических объектов и других факторов. Это

Статья получена 3 июня 2026.

П. В. Матренин, канд. тех. наук, в.н.с., p.v.matrenin@urfu.ru
Федеральное государственное автономное образовательное учреждение высшего образования «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина», Екатеринбург.

приводит к возникновению дрейфа данных и постепенной деградации качества прогнозных моделей [11–13].

Особенно заметно влияние дрейфа данных проявляется в задачах прогнозирования генерации ФЭС, где изменение распределений метеорологических параметров непосредственно влияет на распределение прогнозируемой мощности. В результате ранее обученные модели постепенно теряют актуальность и требуют адаптации к новым условиям функционирования объекта. В последние годы активно исследуются методы адаптивного прогнозирования, основанные на периодическом обновлении моделей, инкрементальном обучении и мониторинге дрейфа данных [12–15]. Однако большинство существующих подходов ориентировано преимущественно на временную адаптацию моделей и недостаточно учитывает наличие различных метеорологических режимов работы объектов ВИЭ.

Дополнительным способом повышения точности прогнозирования является предварительная сегментация данных на группы, соответствующие различным режимам функционирования объекта. Использование методов кластеризации позволяет выделять однородные метеорологические условия и формировать специализированные локальные модели прогнозирования, более точно описывающие отдельные области пространства признаков [7, 16]. Вопросы совместного использования кластеризации и механизмов адаптации моделей к дрейфу данных остаются недостаточно исследованными.

В связи с этим актуальной является задача разработки методов адаптации прогнозных моделей, обеспечивающих одновременный учет временной изменчивости данных и неоднородности метеорологических условий функционирования ФЭС.

В. Связь прогнозирования генерации и планирования режимов работы ФЭС

Планирование режимов работы ФЭС основано на прогнозной информации о выработке электроэнергии. В условиях высокой зависимости солнечной генерации от метеорологических факторов точность прогнозирования непосредственно влияет на качество принимаемых эксплуатационных и диспетчерских решений в задачах диспетчеризации, управления накопителями энергии, формирования графиков выдачи мощности и обеспечения баланса мощности в энергосистеме [17].

Для ФЭС прогнозирование генерации на сутки вперед соответствует циклам оперативного и суточного планирования режимов работы энергетических объектов. Прогноз выработки используется для формирования планового графика генерации, оценки ожидаемых отклонений мощности и определения необходимых управляющих воздействий на оборудование станции и связанные с ней накопители энергии [18].

Полученный прогноз может использоваться для определения графиков заряда и разряда накопителей энергии, планирования обмена мощностью с электрической сетью, минимизации небалансов и

ограничения перегрузок оборудования. В ряде исследований показано, как именно повышение точности прогнозирования приводит к улучшению качества диспетчеризации и снижению эксплуатационных затрат энергетических объектов [19].

Таким образом, задача прогнозирования генерации ФЭС является важным этапом систем поддержки принятия решений при планировании режимов работы объектов солнечной энергетики. Предлагаемый в работе метод временно-метеорологической адаптации направлен на повышение точности таких прогнозов и, следовательно, на повышение эффективности последующих задач оперативного планирования и управления режимами работы ФЭС.

Целью настоящей работы является разработка и исследование метода временно-метеорологической адаптации прогнозных моделей для повышения точности краткосрочного прогнозирования генерации электроэнергии ФЭС. Предлагаемый подход основан на совместном использовании кластеризации метеорологических режимов и периодического обновления моделей машинного обучения на скользящем временном окне.

II. МЕТОД ВРЕМЕННО-МЕТЕОРОЛОГИЧЕСКОЙ АДАПТАЦИИ ПРОГНОЗНЫХ МОДЕЛЕЙ

В задачах прогнозирования генерации электроэнергии ФЭС существенное влияние на качество прогнозирования оказывают как изменение статистических характеристик данных во времени, так и наличие различных режимов функционирования объекта, обусловленных метеорологическими условиями. Использование единой прогнозной модели для всего пространства данных может приводить к снижению точности прогнозирования вследствие неоднородности выборки и возникновения дрейфа данных [16, 20, 21].

Для решения указанной проблемы разработан метод временно-метеорологической адаптации прогнозных моделей. Временно-метеорологическая адаптация модели искусственного интеллекта (ИИ) – это подход к построению и последующему использованию прогнозных моделей ИИ, основанный на (1) автоматическом изменении параметров или структуры прогнозных моделей в соответствии с заданной стратегией адаптации для предотвращения их деградации; (2) кластеризации входных данных для декомпозиции прогнозной модели и учета различных режимов функционирования объекта. На Рис. 1, 2 представлены разработанные алгоритмы построения и применения кластер-ориентированных прогнозных моделей.

Метеорологическая адаптация основана на предварительной кластеризации входных данных по совокупности метеорологических признаков. В качестве признаков кластеризации используются параметры (прогнозные и/или ретроспективные), оказывающие существенное влияние на генерацию ФЭС: солнечная радиация, температура воздуха, облачность, влажность, скорость ветра и другие доступные метеорологические

характеристики. В результате кластеризации формируются группы наблюдений, соответствующие различным режимам функционирования объекта. Для каждого выделенного кластера обучается отдельная локальная прогнозная модель.




Рис. 1: Алгоритм построения прогнозных моделей при использовании кластеризации



Рис. 2: Алгоритм применения прогнозных моделей при использовании кластеризации

При эксплуатации системы новые наблюдения первоначально относятся к одному из выделенных кластеров, после чего прогноз формируется специализированной моделью, обученной на данных

данного кластера. Такой подход позволяет учитывать особенности отдельных метеорологических режимов и снижать влияние неоднородности исходной выборки.

Временная адаптация направлена на компенсацию деградации прогнозных моделей, вызванной изменением статистических характеристик данных во времени. Для этого используется периодическое обновление моделей по мере поступления новых наблюдений. Адаптация выполняется на основе скользящего временного окна, что позволяет учитывать актуальные закономерности функционирования объекта и компенсировать влияние дрейфа данных.

Совместное использование кластеризации и периодического обновления моделей обеспечивает одновременный учет двух важных особенностей задачи прогнозирования генерации ФЭС: наличия различных метеорологических режимов и изменения характеристик данных во времени. В результате достигается повышение точности и устойчивости прогнозирования по сравнению с использованием единой статической модели.

III. РЕЗУЛЬТАТЫ

A. Исходные данные и организация эксперимента

Использован массив почасовых метеорологических данных за многолетний период 1985–2021 гг. для Кемеровской области, содержащий следующие параметры: полная инсоляция на горизонтальную поверхность (Вт/м^2), прямая инсоляция (Вт/м^2), рассеянная инсоляция (Вт/м^2), количество осадков (мм), относительная влажность (%), облачность (%), температура ($^{\circ}\text{C}$) и скорость ветра (км/ч).

Для каждого часа с помощью Pvlb-python [24] рассчитывалась выработка модельной ФЭС установленной мощностью 1 МВт. При расчете учитывались значения инсоляции, угол наклона солнечных панелей, положение Солнца и заданное число панелей. Полученный ряд почасовой выработки, выраженной в $\text{кВт}\cdot\text{ч}$, использовался в качестве целевой переменной. Следует отметить, что целевая переменная представляет собой результат расчетного моделирования, а не измерения выработки ФЭС.

Расчетный ряд использовался как общая основа для сравнения вариантов прогнозирования при одной и той же модели формирования выработки. Такая постановка позволяет исследовать различия между прогнозными алгоритмами в условиях принятой расчетной модели, однако не подтверждает количественную точность прогнозирования измеренной генерации реальной ФЭС.

Исходный обучающий период для всех вариантов прогнозирования был зафиксирован с 1 января 1985 г. по 31 декабря 2014 г. Тестовый период охватывал интервал с 1 января 2015 г. по 31 декабря 2021 г.

Рассматривалась задача краткосрочного прогнозирования выработки ФЭС с горизонтом прогнозирования 24 часа вперед. Для каждого момента времени (t) формировался прогноз выработки ФЭС на момент $(t+24)$, то есть на аналогичный час следующих суток. В качестве целевой переменной использовалась расчетная почасовая выработка ФЭС в $\text{кВт}\cdot\text{ч}$.

Вектор входных признаков включал авторегрессионную, календарную и метеорологическую составляющие. Авторегрессионная составляющая была представлена значениями выработки ФЭС в аналогичный час текущих, предыдущих и предпредыдущих суток. Это позволяло учитывать суточную повторяемость профиля генерации ФЭС.

Календарные признаки включали номер прогнозного часа суток и номер дня в году. Для учета циклической природы этих величин они были преобразованы с использованием синусно-косинусного кодирования.

Метеорологическая составляющая включала прогнозные значения температуры воздуха, количества осадков, скорости ветра и относительной влажности воздуха на 24 часа вперед. Для облачности использовались не прогнозные, а ретроспективные значения: текущая облачность, облачность в аналогичный час предыдущих суток и облачность в аналогичный час предпредыдущих суток. Такое решение связано с высокой неопределенностью прогнозных значений облачности и позволяет использовать более устойчивую ретроспективную информацию о состоянии атмосферы. Инсоляция прогнозируемого часа во входной вектор прогнозной модели не включалась, так что прогнозная модель не получала полного набора входных данных, необходимого для непосредственного расчета выработки за прогнозируемый час. Задача состояла в прогнозировании будущего значения расчетного ряда по метеорологическим прогнозам, календарным признакам и ретроспективной информации. Она не тождественна аппроксимации физической модели при полностью известных входных данных. Вместе с тем полученные метрики характеризуют точность прогнозирования расчетной выработки и не являются непосредственной оценкой точности прогнозирования генерации действующей станции.

Таким образом, прогнозная модель имела вид:

$$P_{t+24}^* = f(P_t, P_{t-24}, P_{t-48}, \sin(2\pi h/24), \cos(2\pi h/24), \sin(2\pi d/365), \cos(2\pi d/365), T_{t+24}, R_{t+24}, W_{t+24}, H_{t+24}, C_t, C_{t-24}, C_{t-48}),$$

где P_{t+24}^* – прогноз выработки ФЭС на 24 часа вперед; P_t – расчетные значения выработки в момент t ; h – прогнозный час суток; d – номер прогнозного дня в году; T, R, W, H – прогнозные значения температуры воздуха, количества осадков, скорости ветра и относительной влажности воздуха на 24 часа вперед; C_t – фактические значения облачности.

Были рассмотрены четыре сценария.

1. Базовый вариант без адаптации и без кластеризации. Единая прогнозная модель обучалась один раз на данных обучающего периода 1985–2014 гг.

2. Вариант с метеорологической адаптацией. На данных обучающего периода 1985–2014 гг. выполнялась кластеризация метеорологических условий с использованием четырех кластеров. Кластеризация осуществлялась один раз алгоритмом k -средних. Для каждого кластера обучалась отдельная прогнозная модель на подмножестве обучающих данных, соответствующем данному кластеру. При

прогнозировании каждое наблюдение тестового месяца относилось к кластеру по значениям метеорологических факторов текущего часа, после чего применялась соответствующая кластерная модель. Во всех вариантах с кластеризацией использовалось фиксированное число кластеров $k = 4$. Число кластеров выбиралось по результатам предварительных экспериментов на обучающей выборке за 1985–2014 гг. Рассматривались значения $k \in \{2, 3, 4, 5, 6\}$; критерием выбора служил средний коэффициент силуэта, характеризующий качество кластеризации. Наибольшее значение критерия получено при $k = 4$. Тестовые данные за 2015–2021 гг. при выборе числа кластеров не использовались.

3. Вариант с временной адаптацией. Исходная модель обучалась на данных обучающего периода 1985–2014 гг. Временная адаптация реализовывалась в режиме скользящего окна длиной 9 лет с частотой обновления один раз в квартал. Перед началом каждого квартала тестового периода модель дообучалась либо повторно обучалась на данных, строго предшествующих текущему кварталу и охватывающих предыдущие 9 лет. Для нейросетевой модели применялось дообучение в течение 200 эпох при фиксированных гиперпараметрах. Для линейной регрессии и ансамблевых моделей выполнялось повторное обучение с нуля на соответствующем адаптационном окне. Гиперпараметры моделей не перенастраивались и использовались в том виде, в котором они были определены для базового варианта. После завершения адаптации модель применялась для прогнозирования на данных тестовых месяцев соответствующего квартала.

Выбранное окно из 9 полных годовых циклов, сохраняет многолетнюю историю метеорологических условий для обучения локальных моделей после кластеризации и одновременно ограничивает глубину используемых данных. Квартальный интервал обновления выбран также эвристически. Он предусматривает включение новых данных в обучение четыре раза в год при меньшем числе запусков обновления, чем ежемесячная схема. Указанные параметры не рассматриваются как оптимальные значения. Анализ чувствительности к длине окна и частоте обновления предполагается выполнить в будущих исследованиях.

4. Вариант с совместной временно-метеорологической адаптацией. Кластеризация метеорологических условий выполнялась один раз на данных обучающего периода 1985–2014 гг. с использованием четырех кластеров и далее не переобучалась. Для каждого кластера формировалась отдельная прогнозная модель. Временная адаптация осуществлялась раз в квартал в режиме скользящего окна длиной 9 лет. Перед началом каждого квартала каждая кластерная модель дообучалась либо повторно обучалась отдельно на адаптационном наборе данных соответствующего кластера, сформированном из данных, строго предшествующих текущему кварталу. При тестировании каждое наблюдение относилось к кластеру по значениям метеорологических факторов текущего часа, после чего прогноз формировался

соответствующей адаптированной кластерной моделью.

В рамках вычислительных экспериментов использовались три типа прогнозных моделей: линейная регрессия (LR), ансамблевая модель на основе случайного леса (RF) и многослойный перцептрон (MLP). Для линейной регрессии применялась стандартная модель без регуляризации. Для модели случайного леса использовалось фиксированное число деревьев, равное 20 с максимальной глубиной 6. MLP имел фиксированную архитектуру, включающую входной слой, три скрытых слоя по 32, 32 и 8 нейронов, соответственно, с функцией активации ReLU, а также выходной слой; обучение выполнялось методом «Adam» в течение 200 эпох.

Для MLP применялось дообучение ранее сформированной модели путем продолжения процесса оптимизации весовых коэффициентов на обновленном наборе данных при сохранении исходной архитектуры сети и фиксированных гиперпараметров. Для ансамблевых моделей выполнялось повторное обучение модели с нуля на обновленном наборе данных, сформированном в пределах текущего скользящего окна. Качество прогнозирования оценивалось по средней абсолютной ошибке (MAE); среднеквадратичной ошибке (RMSE); нормализованной средней абсолютной ошибке (приведенной к среднему значению – nMAE); коэффициенту детерминации (R^2).

В. Полученные результаты

Результаты исследования представлены в таблице 1. Анализ полученных данных показывает, что применение механизмов адаптации приводит к устойчивому повышению точности прогнозирования для всех рассмотренных моделей. Рис. 3, 4 показывают nMAE и относительное снижение ошибки по этой метрике для проведенных вычислительных экспериментов.

Для линейной регрессии использование только метеорологической адаптации позволило снизить значение nMAE с 18,04 до 13,59 %, тогда как временная адаптация обеспечила более умеренное улучшение до 17,12 %. Наилучший результат был достигнут при совместном использовании временной и метеорологической адаптации, при котором значение nMAE составило 12,91 %, что соответствует снижению ошибки на 28,4 % относительно базового варианта.

Аналогичная закономерность наблюдается для модели случайного леса. Значение nMAE уменьшилось

с 12,44 до 10,27 % при использовании метеорологической адаптации и до 11,64 % при использовании только временной адаптации. Совместное применение двух механизмов позволило дополнительно снизить ошибку до 9,66 %, что соответствует улучшению качества прогнозирования на 22,3 %.

Наиболее высокую точность продемонстрировала нейросетевая модель MLP. В базовом варианте значение nMAE составило 11,15 %, тогда как применение метеорологической адаптации позволило снизить его до 8,61 %. При совместной временно-метеорологической адаптации достигнуто минимальное значение nMAE, равное 8,03 %, что соответствует уменьшению ошибки на 28,0 % по сравнению с исходной моделью.

Для MLP дополнительно рассмотрен вариант временной адаптации на расширяющемся окне: перед началом каждого квартала модель дообучалась на всех данных, накопленных с 1 января 1985 г. до начала соответствующего квартала. Частота обновления, способ дообучения, архитектура сети, гиперпараметры и число эпох дообучения совпадали с соответствующими вариантами на скользящем окне. Оценка качества выполнялась на одинаковых тестовых интервалах за 2015–2021 гг. Таким образом, единственным различием являлась глубина обучающей истории: последние девять лет либо все данные, доступные к моменту очередного обновления.

В обоих рассмотренных вариантах MLP конфигурация с девятилетним окном обеспечила несколько меньшую ошибку: разница составила соответственно 0,25 и 0,24 процентного пункта. Результаты показывают, что использование полного объема накопленных данных не обеспечило дополнительного повышения точности относительно рассмотренной конфигурации со скользящим окном. Статистическая значимость различий между этими вариантами отдельно на данном этапе не оценивалась.

Табл. 1: Результаты исследования различных вариантов временно-метеорологической адаптации прогнозных моделей

Модель	Адаптация	Окно	MAE (ср.), кВт	MAE (СКО), кВт	nMAE (ср.), %	RMSE (ср.), кВт	RMSE (СКО), кВт	R^2 (ср.)
LR	Нет	Фиксированное	28,55	8,86	18,04	40,83	12,21	0,86
LR	Метеорологическая	Фиксированное	21,51	6,17	13,59	30,11	8,09	0,89
LR	Временная	Скользящее	27,08	8,35	17,12	38,45	11,36	0,87
LR	В-М	Скользящее	20,42	6,44	12,91	27,97	8,63	0,90
RF	Нет	Фиксированное	19,68	5,34	12,44	25,98	7,16	0,93
RF	Метеорологическая	Фиксированное	16,25	4,38	10,27	20,96	5,59	0,95
RF	Временная	Скользящее	18,40	4,96	11,64	23,74	6,58	0,94
RF	В-М	Скользящее	15,28	4,14	9,66	19,40	5,12	0,95

MLP	Нет	Фиксированное	17,65	4,67	11,15	21,89	5,89	0,94
MLP	Метеорологическая	Фиксированное	13,62	3,68	8,61	17,16	4,67	0,95
MLP	Временная	Скользящее	16,47	4,27	10,41	20,25	5,52	0,94
MLP	В-М	Скользящее	12,70	3,36	8,03	15,74	4,14	0,95
MLP	Временная	Расширяющееся	16,84	4,55	10,66	21,37	5,65	0,94
MLP	В-М	Расширяющееся	13,06	3,55	8,27	16,32	4,31	0,95




Рис. 3: Влияние различных вариантов адаптации на значение pMAE.




Рис. 4. Относительное снижение (nMAE) по сравнению с базовым вариантом прогнозирования.

Следует отметить, что во всех случаях метеорологическая адаптация обеспечивает больший вклад в повышение точности прогнозирования по сравнению с временной адаптацией. Это свидетельствует о существенной неоднородности режимов функционирования ФЭС и подтверждает целесообразность предварительной кластеризации данных по метеорологическим условиям. Вместе с тем наилучшие результаты достигаются при совместном использовании кластеризации и периодического обновления моделей, что подтверждает необходимость одновременного учета как различных режимов работы объекта, так и дрейфа данных во времени.

Дополнительно следует отметить снижение среднеквадратичных отклонений значений MAE и RMSE при использовании временно-метеорологической адаптации. Это указывает не только на повышение средней точности прогнозирования, но и на увеличение устойчивости моделей к изменению условий функционирования объекта.

Полученные значения нормированной средней абсолютной ошибки прогнозирования находятся в диапазоне 8–10 %, что соответствует уровню точности,

достигаемому в современных исследованиях по краткосрочному прогнозированию солнечной генерации [22, 23]. Сопоставимые значения ошибок характерны для моделей, применяемых в регионах с континентальным и смешанным климатом, отличающихся повышенной облачностью и выраженной сезонной изменчивостью метеорологических условий.

Статистическая значимость различий между базовым вариантом прогнозирования и вариантом с временно-метеорологической адаптацией оценивалась с использованием парного непараметрического критерия Уилкоксона, применяемого к месячным значениям MAE, рассчитанным на идентичных тестовых интервалах (таблица 2).

Табл. 2: Статистическая значимость различий между временно-метеорологической адаптацией и базовым вариантом применения модели

Модель	p-значение	Оценка улучшения
Линейная регрессия	$2,51 \cdot 10^{-4}$	Статистически значимое
RF	$5,64 \cdot 10^{-5}$	Статистически значимое
MLP	$3,19 \cdot 10^{-5}$	Статистически значимое

Во всех рассмотренных случаях полученные p-значения существенно меньше уровня значимости 0,05, что подтверждает статистически значимое улучшение качества прогнозирования при использовании временно-метеорологической адаптации.

IV. ЗАКЛЮЧЕНИЕ

В работе предложен метод временно-метеорологической адаптации прогнозных моделей искусственного интеллекта, предназначенный для повышения точности краткосрочного прогнозирования генерации электроэнергии фотоэлектрических станций. Метод основан на совместном использовании

кластеризации метеорологических условий и периодической адаптации моделей к изменяющимся статистическим характеристикам данных.

Проведенное экспериментальное исследование на многолетнем массиве метеорологических данных для Кемеровской области показало, что применение механизмов адаптации позволяет устойчиво повышать качество прогнозирования для различных типов моделей машинного обучения. Установлено, что наибольший вклад в повышение точности вносит метеорологическая адаптация, основанная на декомпозиции пространства данных на кластеры, соответствующие различным режимам функционирования фотоэлектрической станции.

Наилучшие результаты получены при совместном использовании временной и метеорологической адаптации. Для моделей линейной регрессии, случайного леса и многослойного перцептрона значение нормализованной средней абсолютной ошибки было снижено с 18,04 до 12,91 %, с 12,44 до 9,66 % и с 11,15 до 8,03 % соответственно. Полученные результаты свидетельствуют о возможности эффективной компенсации негативного влияния дрейфа данных и неоднородности метеорологических условий на качество прогнозирования.

Ограничением исследования является использование расчетной целевой переменной без проверки на измеренной генерации действующей ФЭС. Также в работе не выполнялось сравнение периодического обновления моделей с адаптацией при детектировании дрейфа. Такое сравнение требует отдельного выбора и проверки критериев обнаружения изменений, порогов срабатывания и длины окна мониторинга с учетом сезонности данных [11]. Поэтому полученные результаты не позволяют судить о преимуществе исследуемой схемы перед адаптацией на основе детектирования дрейфа. Указанные ограничения определяют перспективы дальнейших исследований.

БЛАГОДАРНОСТИ

Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ (тема № FEUZ-2025-0005).

БИБЛИОГРАФИЯ

- [1] Прогноз развития энергетики мира и России 2024 / под ред. А. А. Макарова, В. А. Кулагина, Д. А. Грушевенко, А. А. Галкиной. М.: ИНЭИ РАН, 2024. 208 с.
- [2] Илюшин П. В. Интеграция электростанций на основе возобновляемых источников энергии в Единую энергетическую систему России: обзор проблемных вопросов и подходов к их решению // Вестник Московского энергетического института, 2022, № 4, С. 98–107.
- [3] Матренин П. В., Манусов В. З., Сафаралиев М. Х., Назаров Н. Х. Модели и методы машинного обучения в задачах прогнозирования генерации на основе возобновляемых источников энергии. Новосибирск: Новосибирский государственный технический университет, 2024. 199 с.
- [4] Prema V., Bhaskar M. S., Almakhlles D. [et al.] Critical Review of Data, Models and Performance Metrics for Wind and Solar Power Forecast // IEEE Access, 2022, vol. 10, pp. 667–688.
- [5] Глазунова А. М., Ковальчук Д. В. Алгоритм формирования суточных графиков нагрузок активного энергетического комплекса с ветровой и солнечной станциями // Электричество, 2024, № 8, С. 50–59.
- [6] Wang P., Du E., Zhang N. [et al.] Power system planning with high renewable energy penetration considering demand response // Global Energy Interconnection, 2021, vol. 4 (1), pp. 69–80.
- [7] Benti N. E., Chaka M. D., Semie A. G. Forecasting Renewable Energy Generation with Machine Learning and Deep Learning: Current Advances and Future Prospects // Sustainability, 2023, vol. 15, art. 7087.
- [8] Сергеев Н. Н., Матренин П. В. Обзор международного опыта в прогнозировании генерации возобновляемых источников энергии с помощью методов машинного обучения // iPolytech Journal, 2023, Т. 27, № 2, С. 354–369.
- [9] Горшенин А. Ю., Грицай А. С., Денисова Л. А. Применение машинного обучения деревьев решений для краткосрочного прогнозирования электропотребления // Известия Тульского государственного университета. Технические науки, 2023, № 11, С. 226–231.
- [10] Fang S., Chiang H. A High-Accuracy Wind Power Forecasting Model // IEEE Transactions on Power Systems, 2017, vol. 32 (2), pp. 1589–1590.
- [11] Намют Д. Е., Илюшин Е. А. Мониторинг сдвига данных в моделях машинного обучения // International Journal of Open Information Technologies, 2022, Т. 10, № 12, С. 84–93.
- [12] Bin Kamilin M. H., Yamaguchi S., Bin Ahmadon M. A. Radian Scaling and Its Application to Enhance Electricity Load Forecasting in Smart Cities Against Concept Drift // Smart Cities, 2024, vol. 7, pp. 3412–3436.
- [13] Исаев Ю. Н., Архипова О. В., Ковалев В. З., Хамитов Р. Н. Адаптивное краткосрочное прогнозирование потребления электроэнергии автономными энергосистемами малых северных поселений на основе методов корреляционного анализа // Известия Томского политехнического университета. Инжиниринг георесурсов, 2023, Т. 334, № 2, С. 224–239.
- [14] Глазырин А. С., Боловин Е. В., Архипова О. В. [и др.] Адаптивное краткосрочное прогнозирование потребления электроэнергии автономными энергосистемами малых северных поселений на основе методов ретроспективного регрессионного анализа // Известия Томского политехнического университета. Инжиниринг георесурсов, 2023, Т. 334, № 4, С. 231–248.
- [15] Матренин П. В., Хамитов Р. Н. Алгоритм формирования стратегии автоматического обновления моделей искусственного интеллекта в задачах прогнозирования в электроэнергетике // Инженерный вестник Дона, 2025, № 7, С. 228–247.
- [16] Zhang Z., Wang C., Peng X. [et al.] Solar Radiation Intensity Probabilistic Forecasting Based on K-Means Time Series Clustering and Gaussian Process Regression // IEEE Access, 2021, vol. 9, pp. 89079–89092.
- [17] J. F. L. de Oliveira, P. S. G. de Mattos Neto, H. V. Siqueira [et al.] Forecasting Methods for Photovoltaic Energy in the Scenario of Battery Energy Storage Systems: A Comprehensive Review // Energies, 2023, vol. 16, p. 6638.
- [18] Brenna M., Foadelli F., Longo M., Zaninelli D. Energy Storage Control for Dispatching Photovoltaic Power // IEEE Transactions on Smart Grid, 2018, vol. 9, no. 4, pp. 2419–2428.
- [19] Sharma V., Cortes A., Cali U. Use of Forecasting in Energy Storage Applications: A Review // IEEE Access, 2021, vol. 9, P. 114690–114704.
- [20] Матренин П. В., Хальясмаа А. И., Гамалей В. В. [и др.] Повышение точности прогнозирования генерации фотоэлектрических станций на основе алгоритмов k-средних и k-ближайших соседей // Энергетика. Известия высших учебных заведений и энергетических объединений СНГ, 2023, Т. 66, № 4, С. 305–321.
- [21] Матренин П. В., Хамитов Р. Н. Оперативное прогнозирование выработки ветроэнергетических установок с использованием кластеризации и детектирования выбросов // Проблемы региональной энергетики, 2026, № 1 (69), С. 138–149.
- [22] Arias Velasquez R. M. A Case Study of NeuralProphet and Nonlinear Evaluation for High Accuracy Prediction in Short-Term Forecasting in PV Solar Plant // Heliyon, 2022, vol. 8 (9), art. e10639.
- [23] Du Plessis A. A., Strauss J. M., Rix A. J. Short-Term Solar Power Forecasting: Investigating the Ability of Deep Learning Models to Capture Low-Level Utility-Scale Photovoltaic System Behaviour // Applied Energy, 2021, vol. 285, art. 116395.
- [24] Holmgren W. F., Hansen C. W., Mikofski M. A. pvlib python: a python package for modeling solar energy systems. Journal of Open Source Software, 2018, 3(29), 884. DOI: 10.21105/joss.00884.

Temporal and Meteorological Adaptation of Artificial Intelligence Models for Photovoltaic Power Plant Operation Planning

P. V. Matrenin

Abstract—This paper presents a temporal and meteorological adaptation method for machine learning forecasting models applied to short-term power generation forecasting. The proposed method is based on the combined use of input data clustering and periodic model adaptation during operation. Clustering enables the identification of different operating conditions of the target system and the development of specialized local forecasting models, while temporal adaptation compensates for forecasting performance degradation caused by data drift. To evaluate the effectiveness of the proposed approach, an experimental study was conducted on a short-term photovoltaic power generation forecasting problem. A multi-year dataset of hourly meteorological observations was used. The baseline forecasting approach was compared with temporal adaptation, meteorological adaptation, and combined temporal–meteorological adaptation strategies. The best forecasting performance was achieved through the combined application of temporal and meteorological adaptation, demonstrating the effectiveness of accounting for both data drift and the heterogeneity of meteorological conditions.

Keywords—time series forecasting, machine learning, model adaptation, photovoltaic power generation forecasting, photovoltaic power plant, operational planning.

REFERENCES

- [1] A. A. Makarov, V. A. Kulagin, D. A. Grushevenko, and A. A. Galkina, Eds., *Prognost razvitiya energetiki mira i Rossii 2024* [Forecast of World and Russian Energy Development 2024]. Moscow: ERI RAS, 2024.
- [2] P. V. Ilyushin, “Integratsiya elektrostantsiy na osnove vozobnovlyemykh istochnikov energii v Yedinuyu energeticheskuyu sistemu Rossii: obzor problemnykh voprosov i podkhodov k ikh resheniyu [Integration of renewable energy power plants into the Unified Energy System of Russia: review of challenges and solution approaches],” *Vestnik Moskovskogo energeticheskogo instituta*, no. 4, pp. 98–107, 2022.
- [3] P. V. Matrenin, V. Z. Manusov, M. Kh. Safaraliev, and N. Kh. Nazarov, *Modeli i metody mashinnogo obucheniya v zadachakh prognozirovaniya generatsii na osnove vozobnovlyemykh istochnikov energii* [Machine Learning Models and Methods for Forecasting Renewable Energy Generation]. Novosibirsk: Novosibirsk State Technical University, 2024.
- [4] V. Prema, M. S. Bhaskar, D. Almakhlis [et al.], “Critical Review of Data, Models and Performance Metrics for Wind and Solar Power Forecast,” *IEEE Access*, vol. 10, pp. 667–688, 2022.
- [5] A. M. Glazunova and D. V. Kovalchuk, “Algoritm formirovaniya sutochnykh grafikov nagruzok aktivnogo energeticheskogo kompleksa s vetrovoy i solnechnoy stantsiyami [Algorithm for forming daily load curves of an active energy complex with wind and solar power plants],” *Elektrichestvo*, no. 8, pp. 50–59, 2024.
- [6] P. Wang, E. Du, N. Zhang [et al.], “Power system planning with high renewable energy penetration considering demand response,” *Global Energy Interconnection*, vol. 4 (1), pp. 69–80, 2021.
- [7] N. E. Benti, M. D. Chaka, and A. G. Semie, “Forecasting Renewable Energy Generation with Machine Learning and Deep Learning: Current Advances and Future Prospects,” *Sustainability*, vol. 15, art. 7087, 2023.
- [8] N. N. Sergeev and P. V. Matrenin, “Obzor mezhdunarodnogo opyta v prognozirovaniy generatsii vozobnovlyemykh istochnikov energii s pomoshchyu metodov mashinnogo obucheniya [Review of international experience in forecasting renewable energy generation using machine learning methods],” *iPolytech Journal*, vol. 27 (2), pp. 354–369, 2023.
- [9] A. Yu. Gorshenin, A. S. Gritsay, and L. A. Denisova, “Primenenie mashinnogo obucheniya derevyev resheniy dlya kratkosrochnogo prognozirovaniya elektropotrebleniya [Application of decision-tree machine learning for short-term electricity demand forecasting],” *Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki*, vol. 11, pp. 226–231, 2023.
- [10] S. Fang and H. Chiang, “A High-Accuracy Wind Power Forecasting Model,” *IEEE Transactions on Power Systems*, vol. 32 (2), pp. 1589–1590, 2017.
- [11] D. E. Namiot and E. A. Ilyushin, “Monitoring sdviga dannykh v modelyakh mashinnogo obucheniya [Data drift monitoring in machine learning models],” *International Journal of Open Information Technologies*, vol. 10 (12), pp. 84–93, 2022.
- [12] M. H. Bin Kamilin, S. Yamaguchi, and M. A. Bin Ahmadon, “Radian Scaling and Its Application to Enhance Electricity Load Forecasting in Smart Cities Against Concept Drift,” *Smart Cities*, vol. 7, pp. 3412–3436, 2024.
- [13] Yu. N. Isaev, O. V. Arkhipova, V. Z. Kovalev, and R. N. Khamitov, “Adaptivnoe kratkosrochnoe prognozirovanie potrebleniya elektroenergii avtonomnymi energosistemami malykh severnykh poseleniy na osnove metodov korrelyatsionnogo analiza [Adaptive short-term electricity demand forecasting for autonomous power systems of small northern settlements based on correlation analysis methods],” *Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring geosursov*, vol. 334 (2), pp. 224–239, 2023.
- [14] A. S. Glazyrin, E. V. Bolovin, O. V. Arkhipova [et al.], “Adaptivnoe kratkosrochnoe prognozirovanie potrebleniya elektroenergii avtonomnymi energosistemami malykh severnykh poseleniy na osnove metodov retrospektivnogo regressionnogo analiza [Adaptive short-term electricity demand forecasting for autonomous power systems of small northern settlements based on retrospective regression analysis methods],” *Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring geosursov*, vol. 334 (4), pp. 231–248, 2023.
- [15] P. V. Matrenin and R. N. Khamitov, “Algoritm formirovaniya strategii avtomaticheskogo obnoveniya modeley iskusstvennogo intellekta v zadachakh prognozirovaniya v elektroenergetike [Algorithm for forming a strategy for automatic updating of artificial intelligence models in electric power forecasting problems],” *Inzhenermy vestnik Dona*, no. 7, pp. 228–247, 2025.
- [16] Z. Zhang, C. Wang, X. Peng [et al.], “Solar Radiation Intensity Probabilistic Forecasting Based on K-Means Time Series Clustering and Gaussian Process Regression,” *IEEE Access*, vol. 9, pp. 89079–89092, 2021.
- [17] J. F. L. de Oliveira, P. S. G. de Mattos Neto, H. V. Siqueira [et al.], “Forecasting Methods for Photovoltaic Energy in the Scenario of Battery Energy Storage Systems: A Comprehensive Review,” *Energies*, vol. 16, p. 6638, 2023.
- [18] M. Brenna, F. Foidelli, M. Longo, and D. Zaninelli, “Energy Storage Control for Dispatching Photovoltaic Power,” *IEEE Transactions on Smart Grid*, vol. 9 (4), pp. 2419–2428, 2018.
- [19] V. Sharma, A. Cortes, and U. Cali, “Use of Forecasting in Energy Storage Applications: A Review,” *IEEE Access*, vol. 9, pp. 114690–114704, 2021.
- [20] P. V. Matrenin, A. I. Khalyasmaa, V. V. Gamaley [et al.], “Povyshenie tochnosti prognozirovaniya generatsii fotoelektricheskikh stantsiy na osnove algoritmov k-srednikh i k-blizhaysikh sosedey [Improving photovoltaic generation forecasting accuracy using k-means and k-nearest neighbors algorithms],”

- Energetika. Izvestiya vysshikh uchebnykh zavedeniy i energeticheskikh obedineniy SNG, vol. 66 (4), pp. 305–321, 2023.
- [21] P. V. Matrenin and R. N. Khamitov, “Operativnoe prognozirovanie vyrabotki vetroenergeticheskikh ustanovok s ispolzovaniem klasterizatsii i detektirovaniya vybrosov [Short-term forecasting of wind power generation using clustering and outlier detection],” *Problemy regionalnoy energetiki*, no. 1 (69), pp. 138–149, 2026.
- [22] R. M. Arias Velasquez, “A Case Study of NeuralProphet and Nonlinear Evaluation for High Accuracy Prediction in Short-Term Forecasting in PV Solar Plant,” *Heliyon*, vol. 8 (9), art. e10639, 2022.
- [23] A. A. du Plessis, J. M. Strauss, and A. J. Rix, “Short-Term Solar Power Forecasting: Investigating the Ability of Deep Learning Models to Capture Low-Level Utility-Scale Photovoltaic System Behaviour,” *Applied Energy*, vol. 285, art. 116395, 2021.
- [24] Holmgren W. F., Hansen C. W., Mikofski M. A. pvlib python: a python package for modeling solar energy systems. *Journal of Open Source Software*, 2018, 3(29), 884. DOI: 10.21105/joss.00884