

Алгоритм формирования стратегии автоматического обновления моделей искусственного интеллекта в задачах прогнозирования в электроэнергетике

П.В. Матренин¹, Р.Н. Хамитов²

*¹Уральский федеральный университет имени первого президента
России Б. Н. Ельцина, Екатеринбург*

²Омский государственный технический университет, Омск

Аннотация: Изменение внешних условий, параметров функционирования объектов, взаимосвязей между элементами системы и связей системы с надсистемой приводит к снижению точности результатов моделей искусственного интеллекта, которое называется деградацией моделей. Снижение риска деградации моделей актуально для задач электроэнергетики, особенностью которых является многофакторные зависимости в сложных технических системах и влияние метеорологических параметров. Автоматическое обновление моделей с течением времени является необходимым условием формирования доверия пользователей к интеллектуальным системам прогнозирования. В данной статье представлена классификация видов дрейфа данных. Формализованы варианты решений, которые разработчикам необходимо принять при создании интеллектуальных систем для определения стратегии обновления прогнозных моделей, включая критерии запуска обновления, выбор моделей, оптимизацию гиперпараметров, выбор способа обновления и формирования наборов данных. Предложен алгоритм формирования стратегии автоматического обновления моделей искусственного интеллекта и даны практические рекомендации для разработчиков моделей в задачах прогнозирования временных рядов в электроэнергетике.

Ключевые слова: прогнозирование временных рядов, искусственный интеллект, машинное обучение, доверенная система искусственного интеллекта, деградация моделей, дрейф данных, дрейф концепции.

Введение

Снижение качества работы моделей искусственного интеллекта (ИИ) и статистических моделей с течением времени называется деградацией. Для задач прогнозирования временных рядов в электроэнергетике это особенно актуально, поскольку потребление электроэнергии и ее генерация на основе возобновляемых источников зависит от множества внешних независимых друг от друга факторов [1, 2] и со временем происходят процессы изменения технологических процессов, объема выполняемых работ, обновление оборудования, изменения метеорологических условий, географического ландшафта и т.д.

Как отмечено в работе [3], изменение характеристик данных – скорее правило, чем исключение, поэтому каждая промышленная система ИИ должна отслеживать возможные изменения статистических параметров данных. Система ИИ не может считаться доверенной, если в ней не реализованы механизмы защиты от деградации.

В статье [4] представлено разделение методов предотвращения деградации моделей на активнее и пассивные: пассивные методы обновляют модель постоянно, тогда как активные сперва пытаются детектировать изменения в данных. Статья [3] предлагает архитектуру мониторинга дрейфа.

Если дрейф или деградация обнаружены, возникает вопрос выбора стратегии обновления модели. Наиболее очевидный подход – обучение модели с нуля на обновленном наборе данных, например, раз в месяц либо запуск обучения по событию. В ряде исследований работах предлагаются системы автоматического запуска обучения при детекции дрейфа [5].

В статье [4] предложена рекуррентная нейронная сеть, которая постоянно дообучается на поступающих новых данных, адаптируясь к изменяющимся паттернам графика электропотребления. Эффективность регулярного обновления различных моделей ИИ на примере задачи среднесрочного прогноза речного стока для гидроэнергетики обоснована в исследовании [6]. Существуют и гибридные подходы, такие как комбинация нейронной сети с классической авторегрессионной моделью ARIMA, регулярно обновляемой на вновь поступающих данных [4]. В работе [7] предложен метод адаптивного краткосрочного прогнозирования протреления электроэнергии в изолированных системах, который реализует схему непрерывной идентификации модели.

Перспективным направлением является так называемое трансферное обучение, предполагающее использование зависимостей, выявленных моделью на определенном датасете, для последующего применения в

целевой задаче, данные по которой не входили в изначальный датасет. В статье [8] предложена модель прогнозирования выработки электроэнергии путем предварительного обучения нейросетевой модели на наборе разнородных временных рядов, после чего модель применяется к новой задаче без изменений (zero-shot learning). Авторами [9] предложен алгоритм «Affinity-Driven Transfer Learning», подбирающий наиболее подходящую исходную модель прогноза электропотребления на основе метрики сходства временных рядов и дообучающий её под новую задачу прогнозирования.

При обновлении моделей возникает также вопрос перенастраивания гиперпараметров модели. Исследования показывают, что фиксированные гиперпараметры, оптимальные при изначальном распределении, со временем могут стать неоптимальными [10]. Отдельной задачей является минимизация риска переобучения моделей при автоматическом обновлении. В статье [11] предложена компактная архитектура нейронной сети для оперативного прогноза скорости ветра, которая обеспечивает устойчивость к переобучению и, следовательно, может дообучаться в автоматическом режиме без необходимости дополнительного контроля переобучения.

Исследование [12] показывает связь между выбором способа обновления модели и объемом имеющихся данных в задаче прогноза скорости ветра для ветроэнергетической установки. Также в этой статье показано, что выбор требует проведения экспериментальных исследований чтобы учесть особенности задачи и процессов изменения внешних условий.

Существующие работы описывают различные аспекты защиты систем ИИ от деградации моделей, однако, в них литературе не представлено их итоговое обобщение. В данной работе формализованы все необходимые шаги для формирования целостной стратегии автоматического обновления моделей ИИ; представлена классификация дрейфа данных и описаны

отраслевые рекомендации для решения задач прогнозирования временных рядов в электроэнергетике.

Классификация дрейфа данных

Прогнозирование временных рядов в условиях неопределенности – задача построения оценки y_{t+h}^* значения целевой переменной y_{t+h} временного ряда $\{y_t\}_{t=1}^T$ на основе имеющегося набора наблюдений $\{y_t\}_{t=1}^T$ и экзогенных переменных $T\{X_t\}_{t=1}^T$ при наличии стохастических, структурных и/или априорных неопределенностей, описываемых случайными величинами, вероятностными распределениями, интервальными или нечеткими оценками.

Задача структурно-параметрического синтеза, идентификации и оптимизации прогнозной модели может быть записана следующим образом:

$$f^* = \arg \min_{f \in F} E_{\theta \sim P(\Theta)} \left[L \left(f(\{y_t\}, \{x_t\}; \theta), y_{t+h} \right) \right],$$

где f^* – модель прогнозирования; θ – параметры модели, подверженные неопределенности; L – функция потерь; F – класс допустимых моделей.

Деградация моделей может проявляться различными признаками:

- устойчивое увеличение ошибки модели по различным статистическим критериям;
- явное несоответствие предсказаний модели текущим условиям протекающих процессов.

Если исключить из рассмотрения причины, связанные с ошибками в программном обеспечении, ошибки из-за интеграции с внешними информационными системами и т.п., то остаются два основные причины деградации моделей [13]: утечка данных, дрейф данных.

Утечкой данных в контексте деградации моделей называют недоступность данных по одному или нескольким входным параметрам (признакам). Например, модель среди прочих признаков учитывала данные о температуре воздуха от внешнего метеопровайдера; если в какой-то момент

из-за сбоя на стороне метеопровайдера эти данные перестали поступать в систему, то произойдет утечка данных.

Помимо описанной утечки признаков существует еще два вида утечки: утечка целевой переменной; утечка обучающего/тестового множества.

Утечка целевой переменной означает, что при разработке модели целевая переменная попадает в число входных признаков. Утечка обучающего/тестового связана с предобработкой данных. Если применить предобработку ко всему набору данных, до разделения на обучающий и валидационный/тестовый, то результат может быть лучше, чем если настроить ее только на обучающем, а затем применить к валидационному/тестовому. Также к данному виду утечки относится случайное попадание данных из тестового набора данных в обучающий, но это является ошибкой самой методики построения моделей.

Дрейф данных можно разделить на следующие виды:

- изменение статистических параметров входных переменных (ковариантный дрейф);
- изменение статистических параметров целевых переменных (дрейф целевой переменной);
- изменение зависимостей между входными и выходными переменными (дрейф концепции);

Возможны одновременно два или три указанных видов дрейфа.

Дрейф может быть медленным и быстрым (внезапным). Внезапный дрейф означает скачкообразное изменение. Медленный дрейф разделяется на два вида: плавный дрейф означает изменение без скачкообразных изменений; постепенный дрейф сопровождается быстрыми краткосрочными изменениями, которые происходят несколько раз с возвратами к предыдущему состоянию, но затем после очередного изменения возврата не происходит.

Кроме того, дрейф может быть циклическим. Если цикличность связана с сезонностью, то он называется сезонным. Сезонность характерна для процессов, на которые оказывают влияние метеорологические факторы. Например, модель, обученная на данных, в которые входили не все сезоны года будет иметь выраженный сезонный дрейф.

По направленности дрейф может быть однонаправленным и разнонаправленным: однонаправленный (монотонный) дрейф – параметры распределения данных смещаются в одном направлении; разнонаправленный дрейф – параметры могут смещаться в разных направлениях.

Дрейф также различается по области действия. Локальный дрейф проявляется в ограниченном интервале времени.

При этом важно учитывать особенности предметной области, например, в задаче прогнозирования притока к створу гидроэлектрической станции (ГЭС) по статистическим параметрам (среднее, дисперсия, скорость изменения и т.д.) суточные значения притока в половодье существенно отличаются от притока в период межени, так что статистически весь период половодья может формально считаться локальным дрейфом, хотя с точки зрения достижения целей проекта, это, конечно, ошибочное суждение.

Рис. 1 показывает представленную классификацию.

Дрейф данных обуславливает необходимость адаптации моделей к происходящим изменениям для предотвращения снижения качества их работы с течением времени.

Существует два способа обнаружения дрейфа данных: детектирование; аудит. При детектировании происходит сравнение статистических параметров новых и уже имеющихся входных данных для выявления ковариационного дрейфа. При аудите анализируется изменение показателей точности моделей, что направлено в первую очередь на выявление дрейфа концепции.




Рис. 1. – Классификация дрейфа данных

Возникает задача выбора способа анализа, заключающаяся в выборе совокупности измерений для анализа. Если рассматривать небольшие входящие наборы данных, то детектирование дрейфа может выполняться без существенной задержки, но высок риск ложных срабатываний, поскольку будет рассматриваться недостаточно большой объем данных. Например, если рассматривать задачу, в которой используются метеорологические признаки, то их распределение за несколько лет будет существенно отличаться от распределения за любую отдельную неделю, месяц и даже сезон года. В то же время анализ больших объемов новых данных приведен к задержке детектирования дрейфа.

Для настройки алгоритма детектирования или аудита можно выполнить валидацию на ретроспективных данных, взяв некоторую самую раннюю по времени часть за базовую и затем проверяя алгоритм при постепенном добавлении более новых данных.

Методы обновления моделей

Для определенности дальнейшего изложения необходимо привести определения ряда терминов.

Обучение – процесс оптимизации параметров модели, которые еще не были настроены на каком-либо наборе данных.

Дообучение – процесс, когда обученная модель обучается на других данных, которые могут включать в себя полностью или частично данные, на которых была обучена модель.

Тонкая настройка – процесс дообучения, когда оптимизируется лишь некоторая часть параметров модели, например, последние полносвязные слои глубокой нейросетевой модели.

Трансферное обучение – то же, что и дообучение, но чаще под трансферным обучением понимается тонкая настройка при решении несколько отличающейся задачи.

Таким образом, термин трансферное обучение обычно используется, когда речь идет не об обновлении модели для учета дрейфа данных, а о применении обученной модели в другой задаче. Например, модель прогноза притока к створу одной ГЭС может быть использована для прогноза притока к створу другой ГЭС в результате трансферного обучения; модель прогноза электропотребления нескольких регионов (каждого, а не суммарного) может быть использована для другого региона. Особенно полезен такой подход в случаях, когда не доступен достаточный данных для новой задачи, что часто бывает при вводе к эксплуатации новых объектов, таких как промышленные предприятия, электрические станции на возобновляемых источниках энергии.

Для упрощения текста ниже при использовании понятия «обучение/дообучение» предполагается также, что тонкая настройка также в него входит.

Автоматическое обновление модели – «обучение/дообучение» модели, которое запускается автоматически по некоторому критерию на основе анализа входных и выходных данных модели или по расписанию.

Автоматическое машинное обучение – концепция, согласно которой выбор модели, ее гиперпараметры, в том числе и архитектура модели выбираются автоматически на основе анализа данных. Автоматическое машинное обучение представляет собой набор методов и технологий, направленных на автоматизацию процесса разработки моделей машинного обучения. Недостатком автоматического машинного обучения является необходимость использовать мощные вычислительные центры для многократного обучения множества моделей и их вариантов.

Алгоритм поддержки принятия решений при формировании стратегии автоматического обновления моделей

Реализация автоматического обновления моделей требует комплексного подхода, включающего выбор подходящих алгоритмов, оптимизацию гиперпараметров, мониторинг производительности и автоматическое обновление моделей.

Стратегия автоматического обновления модели должна отвечать на приведенные ниже вопросы.

1. Критерий запуска обучения/ дообучения модели. Возможные варианты:

- ухудшение показателей точности по результатам аудита дрейфа концепции (в этом случае необходимо выбрать показатели, пороги ухудшения и объем новых данных, на которых они будут вычисляться);
- достижение определенного объема новых данных;
- детектирование ковариантного дрейфа (необходимо определить на каком объеме новых данных вычислять статистические параметры признаков);

- плановое обновление по календарному расписанию. Выбор зависит от особенностей задачи, но целесообразно протестировать все варианты на ретроспективных данных.

2. Выполнение выбора модели. Возможные варианты:

- выполнять выбор модели из некоторого набора
- использовать ранее созданную модель (имеет ввиду модель или метод в общем виде, например, рекуррентная нейронная сеть или метод опорных векторов без фиксации гиперпараметров).

Если не предполагается существенного изменения условий задачи, то выбор модели не следует менять поскольку он требует высоких вычислительных затрат и несет риски ошибок в случае автоматизации выбора.

3. Выполнение оптимизации гиперпараметров модели. Возможные варианты: выполнять (необходим выбор метода); не выполнять.

Аналогично с предыдущим вопросом. Но если стратегия предполагает выбор модели, то оптимизация гиперпараметров необходима.

4. Выбор способа автоматического обновления. Возможные варианты:

- тонкая настройка (требуется выбор настраиваемых параметров);
- дообучение;
- обучение.

Выбор зависит от особенностей задачи, степени изменения закономерностей в данных, но имеет смысл протестировать все варианты на ретроспективных данных.

5. Определение набора данных для выполнения действий, выбранные в пунктах 2–4. Возможные варианты:

- только на новых данных (необходимо выбрать минимальный объем новых данных);

- на данных, на которых модель была обучена с добавлением новых данных;
- на данных, попавших в рамки плавающего окна (требуется выбор ширины окна).

Последний вариант означает, что старые данные удаляются из обучающего набора, так что ее объем остается постоянным при добавлении новых данных. Также этот вариант может быть обобщен путем введения весов значимости объектов выборки, так что старые объекты не исключаются, но их вес постепенно снижается, а новые объекты имеют максимальный вес на момент добавления к выборке.

Два последних варианта имеют также общее обозначение «инкрементное обучение».

Выбор следует выполнять путем анализа всех вариантов на ретроспективных данных. Например, в статье [12] рассмотрены варианты автоматического обновления модели для прогноза скорости ветра и показано, что, во-первых, дообучение нейросетевой модели на новых данных снижает ошибку прогнозирования, при этом достаточно лишь раз в месяц запускать дообучение модели на новых данных; во-вторых, обучение модели с нуля на относительно небольшом количестве новых данных (три года) оказалось наименее эффективным вариантом. Это показывает, что длительность обучающего набора данных может быть более важным фактором, чем новизна используемой информации.

На рис. 2 приведена укрупненная схема алгоритма формирования стратегии на основе приведенных рекомендаций.

Если обучения модели требует высоких затрат вычислительных ресурсов, то это позволит минимизировать их использование, запуская процесс обучения/дообучения лишь при необходимости. Также необходимо

отслеживать изменения в статистических параметрах входных данных для обнаружения дрейфа.




Рисунок 2 – Алгоритм выбора стратегии автоматического обновления моделей ИИ

Важно протестировать на ретроспективных данных, что выбранный размер набора новых данных для анализа при будет приводить к ложному срабатыванию детектора дрейфа, например из-за сезонности.

Если обучение не требует высоких затрат вычислительных ресурсов, то целесообразно реализовать процесс автоматической обновления моделей с новыми данными.

В качестве дополнительных рекомендаций определены следующие:

- использование техники дополнения данных (data augmentation), для повышения обобщающей способности модели, особенно при работе с небольшими наборами данных;
- внедрение механизмов автоматического обнаружения и обработки аномалий;
- учет требований информационной безопасности для предотвращения подмены обучающей выборки и хищения данных и моделей.

Особенности автоматического обновления моделей искусственного интеллекта в задачах прогнозирования в электроэнергетике

Автоматическое обновление моделей ИИ в задачах прогнозирования потребления и генерации электроэнергии имеет ряд преимуществ и перспектив. Примеры ниже приведены для задач гидроэнергетики, как требующих учета большего количества факторов, но они справедливы и для других электрических станций на базе возобновляемых источников энергии (то есть в условия неопределенности) и для прогноза нагрузки.

1. Автоматическое обновление моделей позволяет учесть изменения в данных и условиях работы, что приводит к более точным прогнозам. Гидрологические условия могут существенно меняться со временем из-за климатических изменений, антропогенного воздействия и других факторов. Автоматическое обучение/дообучение позволяет моделям адаптироваться к новым данным и учитывать эти изменения, что повышает точность прогнозов.

2. Автоматическое обучение/дообучение моделей позволяет снизить затраты на ручное обновление моделей и повысить производительность

труда как разработчиков моделей, так и пользователей – специалистов, занимающихся планированием генерации или потребления электроэнергии.

3. Поскольку со временем накапливается большое количество новых данных, которые могут быть использованы для улучшения модели, автоматическое обучение/дообучение позволяет интегрировать эти данные в обучающий набор без необходимости ручной перенастройки модели, что повышает ее общую эффективность.

4. Без обновления модель может «устаревать» и терять свою способность точно прогнозировать на основе изменяющихся условий. Автоматическое обновление повышает вероятность того, что модель всегда остается релевантной внешним условиям.

Ниже приведены результаты применения алгоритма формирования стратегии обновления модели для задачи прогноза притоку к створу ГЭС, необходимого для планирования ее выработки.

1. Критерий запуска обучения/ дообучения модели. Поскольку ухудшение показателей может быть связано с природными катаклизмами, приведшим, например, к уничтожению нескольких используемых для сбора данных метеорологических или гидрологических постов, а также непредсказуемыми антропогенными факторами, то критерий запуска автоматического обучения/дообучения не может быть основан на ухудшении показателей точности.

В рассматриваемой задаче данные приходят с постоянной частотой, поэтому то варианты «достижение определенного объема новых данных» и «плановое обновление по календарному расписанию» оказываются идентичными. Более того, детектирование ковариантного дрейфа в данной задаче также корректно свести к плановому обновлению, поскольку корректное определение изменения статистических параметров входных данных возможно только с учетом сезонности. Выбран вариант запуска

автоматического обновления моделей ежегодно гарантированно после окончания половодья, например, 1 июля каждого года.

2. Выполнение выбора модели. Как правило, в задачах прогноза гидрологических параметров разрабатываются специализированные модели, учитывающие особенности данных, совмещающие методы ИИ с физико-математическими моделями, и имеющими другие причины, по которым выбор модели при их автоматическом обновлении не выполняется.

3. Выполнение оптимизации гиперпараметров модели. Так как автоматическое обновление выполняется один раз в год, то оптимизация гиперпараметров не требует существенных вычислительных затрат относительно общих затрат на эксплуатацию модели. Рекомендуется использование алгоритма случайного поиска гиперпараметров с генерацией множества (сотни или даже тысячи) вариантов.

Для пунктов 2-3 необходим выбор критерия, по котором автоматически выбиралась бы модель или набор гиперпараметров модели. Выбрано среднеквадратическое отклонение (СКО) по следующим причинам: СКО эффективен при вычислении производных и использовании методов градиентного спуска, так как возведение ошибки в квадрат приводит к гладким и непрерывным функциям, что помогает находить минимум функции потерь более эффективно; использование СКО делает модель более чувствительной к большим ошибкам, что важно для задачи прогнозирования притока;

4. Выбор способа автоматического обновления. Так как запуск автоматического обновления выполняется раз в год, появляется возможность не экономить вычислительные ресурсы и применять не тонкую настройку и не дообучение модели, а ее обучение с применением кросс-валидации. Также выбор основан на решении выполнять оптимизацию гиперпараметров модели в пункте 3.

5. Определение набора данных для выполнения действий, выбранные в пунктах 2–4. На основе анализа существующих исследований, таких как [14–17] сделаны следующие выводы по определению набора данных:

- рекомендуется использовать обучающий набор данных не менее 10-20 лет данных, что позволяет учесть различные гидрологические циклы и сезонные вариации;

- для более точных и надежных прогнозов многие исследователи рекомендуют использовать обучающие наборы данных длительностью от 20 лет и более;

- в регионах с выраженной сезонностью важно иметь достаточное количество лет данных для адекватного моделирования сезонных паттернов, это также требует набора данных длительностью не менее 20 лет.

Таким образом, набор для обучения и валидации модели составляется из доступных данных не более чем за 20 лет, кроме того, в нее включается год с самым половодным паводком по суммарному объему притока и период половодья, и самый маловодный.

Заключение

В работе предложена комплексная стратегия автоматического обновления моделей искусственного интеллекта, ориентированная на задачи прогнозирования в электроэнергетике. В отличие от существующих подходов, фокусирующихся преимущественно на отдельных аспектах сопровождения моделей (детектировании дрейфа или периодическом переобучении), разработанная стратегия охватывает весь цикл принятия решений: от момента запуска обновления до формирования обучающего набора данных с учетом особенностей предметной области.

Полученные результаты могут быть использованы при создании интеллектуальных систем поддержки принятия решений в электроэнергетике, ориентированных на работу в условиях

неопределенности и нестационарной среды. В дальнейшем возможно расширение предложенной стратегии на задачи прогнозирования в других отраслях, где проявляются схожие эффекты деградации моделей под действием дрейфа данных.

Литература

1. Khalyasmaa A.I., Eroshenko S.A., Tashchilin V.A. [et al]. Industry experience of developing day-ahead photovoltaic plant forecasting system based on machine learning // Remote Sensing. 2020. Vol. 12 (20). pp. 1-21.
2. Русина А.Г., Тувшин О., Матренин П.В., Попов Н.С. Прогнозирование суточного графика электропотребления рабочих дней с учетом метеофакторов для центральной энергосистемы Монголии // Известия высших учебных заведений. Проблемы энергетики. 2022. Т. 24, № 2. С. 97–106.
3. Намиот Д.Е. Ильюшин Е.А. Мониторинг сдвига данных в моделях машинного обучения // International Journal of Open Information Technologies. 2022. Т. 10, № 12. С. 84–93.
4. Bayram F., Aupke P., Ahmed B.S. [et al]. DA-LSTM: A Dynamic Drift-Adaptive Learning Framework for Interval Load Forecasting with LSTM Networks // ArXiv. 2023. URL: [/arxiv.org/pdf/2305.0876](https://arxiv.org/pdf/2305.0876) (дата обращения 01.03.2025).
5. 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.
6. 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.

7. Сафаралиев М.Х., Кокин С.Е., Дмитриев С.А. [и др.]. Разработка моделей среднесрочного прогнозирования притока воды для планирования выработки электроэнергии в изолированных энергосистемах // Электричество. 2022. № 5. С. 58–68.

8. Kamalov F., Sulieman H., Moussa S. [et al]. Powering Electricity Forecasting with Transfer Learning // Energies. 2024. Vol. 17 (3). P. 626.

9. Rebei A., Amayri M., Bouguila N. Affinity-Driven Transfer Learning for Load Forecasting // Sensors. 2024. Vol. 24 (17). pp. 5802.

10. Veloso B., Gamav, Malheiro B., Vinagre J. Hyperparameter Self-Tuning for Data Streams // Information Fusion. 2021. Vol. 76. pp. 75–86.

11. Матренин П.В., Манусов В.З., Игумнова Е.А. Устойчивое краткосрочное прогнозирование скорости ветра с помощью адаптивных компактных нейронных сетей // Проблемы региональной энергетики. 2020. № 3(47). С. 69–80.

12. Matrenin P.V., Rusina A.G., Kyrianova N.G., Sergeev N.N. Short-Term Wind Speed Forecasting for an Autonomous Hybrid Power Plant of a Traction Railway Substation // 23rd International Conference of Young Professionals in Electron Devices and Materials (EDM), Aya, 2022. Vol. 23. pp. 411–415.

13. Хальясмаа А.И., Матренин П.В., Ерошенко С.А. Анализ ошибок применения алгоритмов машинного обучения в задачах электроэнергетики // Электроэнергия. Передача и распределение. 2021. № 3(66). С. 46–53.

14. Мотовилов Ю.Г., Гельфан А.Н. Модели формирования стока в задачах гидрологии речных бассейнов. М.: Изд. РАН. 2018. 300 с.

15. Watson A., Midgley G., Ray P., Kralisch S., Helmschrot J. How Climate Extremes Influence Conceptual Rainfall-Runoff Model Performance and Uncertainty // Frontiers in Climate. 2022. Vol. 4. P. 859303.

16. Stephens C., Marshall L., Johnson F. Investigating strategies to improve hydrologic model performance in a changing climate // Journal of Hydrology. 2019. Vol. 579. P. 124219.

17. Gao C., He Z., Pan S., Weidong, X., Xu Y. Effects of climate change on peak runoff and flood levels in Qu River Basin, East China // Journal of Hydro-environment Research. 2018. Vol. 28. pp. 34–47.

References

1. Khalyasmaa A.I., Eroshenko S.A., Tashchilin V.A. [et al]. Industry experience of developing day-ahead photovoltaic plant forecasting system based on machine learning. Remote Sensing. 2020. Vol. 12 (20). pp. 1-21.

2. Rusina A.G., Tuvshin O., Matrenin P.V., Popov N.S. Izvestiya vysshikh uchebnykh zavedeniy. Problemy energetiki. 2022. Vol. 24, № 2. pp. 97–106.

3. Namiot D.Y. Ilyushin Y.A. International Journal of Open Information Technologies. 2022. Vol. 10, № 12. pp. 84–93.

4. Bayram F., Aupke P., Ahmed B.S. [et al]. DA-LSTM: A Dynamic Drift-Adaptive Learning Framework for Interval Load Forecasting with LSTM Networks. ArXiv. 2023. URL: arxiv.org/pdf/2305.0876 (date accessed: 01.03.2025).

5. 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.

6. Glazyrin A.S., Bolovin E.V., Arkhipova O.V. [et al]. Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov. 2023. Vol. 334. № 4. pp. 231–248.

7. Safaraliev M.Kh., Kokin S.E., Dmitriev S.A. [et al]. Elektrichestvo. 2022. № 5. pp. 58–68.

8. Kamalov F., Sulieman H., Moussa S. [et al]. Powering Electricity Forecasting with Transfer Learning. Energies. 2024. Vol. 17 (3). P. 626.

9. Rebei A., Amayri M., Bouguila N. Affinity-Driven Transfer Learning for Load Forecasting. *Sensors*. 2024. Vol. 24 (17). pp. 5802.
10. Veloso B., Gamav, Malheiro B., Vinagre J. Hyperparameter Self-Tuning for Data Streams. *Information Fusion*. 2021. Vol. 76. pp. 75–86.
11. Matrenin P.V., Manusov V.Z., Igumnova E.A. Problemy regionalnoy energetiki. 2020. № 3(47). pp. 69–80.
12. Matrenin P.V., Rusina A.G., Kyrianova N.G., Sergeev N.N. Short-Term Wind Speed Forecasting for an Autonomous Hybrid Power Plant of a Traction Railway Substation. 23rd International Conference of Young Professionals in Electron Devices and Materials (EDM), Aya, 2022. Vol. 23. pp. 411–415.
13. Khalyasmaa A.I., Matrenin P.V., Eroshenko S.A. Elektroenergiya. Peredacha i raspredeleniye. 2021. № 3(66). С. 46–53.
14. Motovilov Y.G., Gelfan A.N. Modeli formirovaniya stoka v zadachakh gidrologii rechnykh basseynov. [Flow formation models in river basin hydrology problems]. Moskva: Izd. Rossiyskoy akademii nauk. 2018. 300 p.
15. Watson A., Midgley G., Ray P., Kralisch S., Helmschrot J. How Climate Extremes Influence Conceptual Rainfall-Runoff Model Performance and Uncertainty. *Frontiers in Climate*. 2022. Vol. 4. P. 859303.
16. Stephens C., Marshall L., Johnson F. Investigating strategies to improve hydrologic model performance in a changing climate. *Journal of Hydrology*. 2019. Vol. 579. P. 124219.
17. Gao C., He Z., Pan S., Weidong, X., Xu Y. Effects of climate change on peak runoff and flood levels in Qu River Basin, East China. *Journal of Hydro-environment Research*. 2018. Vol. 28. pp. 34–47.

Дата поступления: 3.05.2025

Дата публикации: 25.06.2025