

## ЭЛЕКТРО- И ТЕПЛОЭНЕРГЕТИКА

УДК 621.311

[https://doi.org/10.18503/2311-8318-2022-4\(57\)-4-11](https://doi.org/10.18503/2311-8318-2022-4(57)-4-11)

Сафаралиев М.Х.<sup>1</sup>, Матренин П.В.<sup>2</sup>, Кирьянова Н.Г.<sup>2</sup>, Гуломзода А.Х.<sup>2</sup>

<sup>1</sup> Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург

<sup>2</sup> Новосибирский государственный технический университет

### СРЕДНЕСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ НА ОСНОВЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ В ИЗОЛИРОВАННЫХ ЭНЕРГОСИСТЕМАХ

В условиях резко переменных климатических условий высокогорья, территориальной распределенности, дефицита генерирующих мощностей, дороговизны углеродного топлива и отсутствия больших накопителей энергии, обеспечивающих покрытие пиковых нагрузок, в горных изолированных энергосистемах (ИЭС) возрастает необходимость обеспечения балансовой надежности с учётом оптимального распределения ресурсов. Для обеспечения требуемой балансовой надежности необходима реализация достоверного прогнозирования электропотребления в среднесрочной перспективе для планирования загрузки генерирующего оборудования с учетом необходимого и достаточного покрытия нагрузки, стоимости генерации, экологичности и других критериев. Поэтому к точности и рабочести прогноза нагрузки предъявляются повышенные требования. Проведено исследование влияния метеорологических факторов на среднесрочное прогнозирование электропотребления ИЭС Горно-Бадахшанской автономной области (ГБАО), расположенной в Республике Таджикистан, для которой характерны вышеперечисленные специфические свойства ИЭС. Для прогнозирования электропотребления с учетом метеорологических факторов использована нейросетевая модель. Чтобы повысить эффективность обучения модели, предложен подход, основанный на кластеризации метеорологических условий. Своя нейросетевая модель создается для каждого кластера, кроме того, обучена вспомогательная модель, которая относит текущие условия к одному из кластеров. Таким образом, вместо единой модели, которая учитывала бы все возможные условия, создана система из намного более простых моделей, что повышает интерпретируемость процедуры прогнозирования и снижает риск переобучения.

**Ключевые слова:** среднесрочное прогнозирование электропотребления, адаптивные модели машинного обучения, метеорологические условия, изолированная энергосистема, кластеризация

#### ВВЕДЕНИЕ

Среднесрочное прогнозирование чрезвычайно важно для поставщиков энергии и других участников рынков производства, передачи и распределения электроэнергии. Это помогает принимать решения, в том числе о покупке и производстве электроэнергии в электроэнергетической системе. Основная роль прогнозирования электропотребления в такой системе заключается в повышении точности планирования производства и купли-продажи необходимого объема электроэнергии [1-3].

Большинство методов прогнозирования электропотребления посвящены краткосрочному прогнозированию (от нескольких минут до 24 часов), а не среднесрочному (от нескольких дней до нескольких месяцев). Как правило, методы прогнозирования электропотребления можно разделить на две широкие категории [4]: статистические методы и методы на основе машинного обучения, хотя граница между ними является нечеткой.

Традиционные статистические методы включают метод временных рядов [5, 6], метод фильтра Калмана [7], метод экспоненциального сглаживания [8] и т.д. Однако точность традиционных методов прогнозирования может быть недостаточно высокой на среднесрочную перспективу из-за нелинейных характеристик электропотребления для прогнозирования процессов с высокой степенью волатильности. Последнее особенно характерно для ИЭС из-за их небольшого размера относительно крупных региональных и объединенных энергосистем. Методы прогнозирования, основанные на машинном обучении, включают классические ис-

кусственные нейронные сети [9], метод опорных векторов (support vector machine, SVM) [10], нейронные сети с памятью [11] и множество других методов. По сравнению с традиционными методами, точность прогнозирования методов машинного обучения во многих случаях существенно выше, но оптимизация параметров каждой модели затруднена, что влияет на эффективность прогнозирования.

Одним из подходов к повышению точности прогнозов является использование дополнительных этапов фильтрации и предобработки данных, в том числе с помощью кластеризации. Кластеризация позволяет строить вместо единой модели для всех условий функционирования ряд отдельных моделей, каждая из которых лучше адаптирована к определенным метеорологическим условиям. При этом для текущих условий среди всех ретроспективных данных формируется выборка из наиболее похожих записей, затем на этих данных обучается модель. Чаще всего кластеризация метеорологических условий в задачах электроэнергетики связана с прогнозированием генерации возобновляемых источников энергии.

Кластеризация может быть использована и для фильтрации данных. В [12] авторы описывают применение кластеризации метеорологических параметров для обнаружения выбросов. При анализе электропотребления кластеризация также применяется. Например, для разделения потребителей по профилям электропотребления [13, 14].

В данной работе кластеризация применена для разделения выборки ретроспективных данных на несколько категорий, различающихся по метеорологическим условиям. Для каждого кластера создается своя модель прогнозирования нагрузки. Также отличием предложенного подхода является алгоритм выбора

оптимального числа предыдущих дней, метеорологические данные которых используются для кластеризации. Для этого применен алгоритм снижения размерности массива данных Principal Component Analysis (Анализ Главных Компонентов) (PCA), который позволяет визуально оценить, как распределились кластеры в пространстве признаков. Также алгоритм PCA позволил упростить прогнозные модели за счет агрегирования метеорологических данных.

#### ОПИСАНИЕ ВЫБОРКИ ДАННЫХ

В Республике Таджикистан сектором электроэнергии управляет Открытая акционерная холдинговая компания (ОАХК) «Барки Точик», которая является государственной собственностью. Предприятие контролирует электрические станции и сети, выработку, передачу и распределение электроэнергии в Республике Таджикистан, за исключением ГБАО. Так, с декабря 2002 г. сеть электроснабжения ГБАО перешла от компании «Барки Точик» к частной компании «Памир Энерджи» на основе Концессионного соглашения сроком на 25 лет и начала работать изолированно, то есть без связи с основной энергосистемой республики [15].

В настоящее время в управлении «Памир Энерджи» находятся 11 ГЭС и одна солнечная электростанция (СЭС) общей установленной мощностью 43,5 МВт, из которых более крупные – ГЭС «Памир-1» и «Хорог», а также несколько ДЭС малой мощности. ДЭС подключаются к системе в параллельную работу в основном зимой, когда в энергосистеме наблюдается нехватка электроэнергии [16].

Поскольку дефицит электроэнергии в ГБАО,рабатываемой ГЭС, наблюдается только в холодный период (с ноября по март включительно) [17, 18], рассмотрены данные только за эти месяцы (рис. 1 и 2).

Основная гипотеза данного исследования заключается в возможности повысить точность среднесрочного прогнозирования электропотребления за счет использования метеорологических данных и кластеризации метеорологических условий.

Кроме того, в рассматриваемой энергосистеме нагрузка меняется в выходные дни, поэтому в выборку добавлен номер дня недели. Номера года, месяца и дня также рассмотрены в качестве признаков. Ниже приведен полный список признаков в исходной выборке данных:

- год;
- месяц;
- день;
- день недели;
- температура воздуха;
- относительная влажность воздуха;
- скорость ветра;
- облачность.

Электропотребление (среднесуточная мощность нагрузки) является целевой переменной.

Выборка содержит записи с шагом 1 сутки за 6 лет (2015–2020 гг.). Таким образом, выборка содержит 908 строк и 9 столбцов.

Коэффициенты корреляции между признаками и электропотреблением приведены в табл. 1. Видно, что наибольшая зависимость наблюдается между электропотреблением и годом и между электропотреблением и днем недели, но метеорологические факторы, такие как температура, влажность и скорость ветра, тоже оказывают влияние на электропотребление.




Рис. 1. Графики электропотребления за январь-март 2019 г.




Рис. 2. Графики электропотребления за ноябрь-декабрь 2019 г.

**Таблица 1**  
Коэффициент корреляции между признаками и электропотреблением

Признак	Коэффициент корреляции
Год	0,70
Месяц	-0,09
День	0,01
День недели	-0,51
Температура	-0,33
Влажность	0,20
Скорость ветра	-0,37
Облачность	0,01

#### ПОСТАНОВКА ЗАДАЧИ ПРОГНОЗИРОВАНИЯ

Необходимо построить модель среднесрочного (на неделю вперед) прогнозирования электропотребления энергосистемы:

$$P_i^* = f(W_{i-7}, W_{i-8}, \dots, W_{i-6-d}), \quad (1)$$

где  $P_i^*$  – прогнозное электропотребление в  $i$ -е сутки;  $f$  – модель;  $W_j$  – вектор значений используемых признаков в  $j$ -е сутки, включающий в себя и  $P_j$ ;  $d$  – число предыдущих дней, использованных для прогнозирования.

В работе не используются прогнозы метеорологических факторов, поскольку в этом случае система окажется зависимой от точности среднесрочных прогнозов метеопровайдеров. Для прогнозирования используются данные за предыдущие сутки (с учетом того, что горизонт планирования составляет неделю).

Точность прогноза оценивается на тестовой выборке с использованием метрик mean absolute error (MAE), mean absolute percentage error (MAPE) и root mean squared error (RMSE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - P_i^*|; \quad (2)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i - P_i^*}{P_i} \right|; \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - P_i^*)^2}, \quad (4)$$

где  $n$  – размер тестовой выборки в сутках;  $P$  – истинное значение электропотребления;  $P^*$  – прогнозное значение электропотребления.

#### КЛАСТЕРИЗАЦИЯ МЕТЕОРОЛОГИЧЕСКИХ УСЛОВИЙ

При построении моделей машинного обучения необходимо сделать выбор: создавать единую модель, которая будет решать всю задачу целиком, или разбить задачу на этапы и создавать отдельные модели для каждой из них.

Создание единой модели позволяет выполнять ее обучение для достижения конечной цели, в то время как при разбиении задачи на этапы каждая модель строится для достижения подцели. Затем результаты объединения таких моделей могут оказаться не столь качественными, как при обучении единой модели, сфокусированной на конечном результате. С другой стороны, в задачах планирования и управления в электроэнергетике очень важна интерпретируемость моделей машинного обучения, гарантия их робастности и снижение риска неожиданного поведения [19].

Кроме того, нужно учитывать ограниченность выборки данных. Чем меньше выборка, тем менее надежными являются выводы, полученные с использованием сложных моделей. Разбиение задачи на части позволяет применять более простые модели на каждом этапе и контролировать их. Ограничение размера модели может сделать ее более устойчивой к переобучению, более робастной и повысить ее обобщающую способность [20].

Поэтому в данной работе использована следующая архитектура системы прогнозирования на базе машинного обучения:

- 1) уровень предобработки данных;
- 2) уровень кластеризации данных;
- 3) уровень прогнозирования, состоящий из  $m$  независимых нейронных сетей, по числу кластеров.

#### ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ

Суть предложенного подхода заключается в разбиении метеорологических условий на  $m$  кластеров с помощью машинного обучения без учителя (алгоритм k-means [21]). Для каждого кластера выполняется построение своей нейросетевой модели. При работе системы входные данные относятся к одному из кластеров, и затем для получения прогноза применяется та модель, которая была построена для этого кластера.

Такой подход имеет следующие преимущества:

- этап кластеризации выполняется без учителя, значит, по определению исключен риск подгонки под нужный результат;
- можно визуально проверить логичность результата кластеризации, применив после кластеризации метод главных компонент и визуализировав полученные кластеры на плоскости;
- построение разных моделей для отдельных метеорологических условий позволяет повысить точность прогноза, поскольку каждая модель оказывается сфокусированной на определенных условиях работы;
- отдельные модели могут быть более компактными, чем единая – следовательно, для их обучения и тестирования можно использовать меньше данных, а их работа будет более предсказуемой.

#### РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

##### 1. Предобработка данных.

Исходная выборка данных может быть записана как

$$\{(W_i, P_i)\}, i = 1 \dots n.$$

На этапе предобработки она переводится в следующий вид, соответствующий выражению (1):

$$\{(W_{i-7}, W_{i-8}, \dots, W_{i-6-d}, P_i)\}.$$

Число  $d$  определяет количество предыдущих суток, которые будут использоваться для построения прогноза. При  $d$ , равном 1, полученный датасет будет иметь 10 столбцов (9 признаков и целевую переменную), при  $d$  равном 2 – 19 и т.д.


Кроме того, на этапе предобработки данных выполняется Min-Max нормализация, чтобы все значения признаков оказались в диапазоне от 0 до 1.

##### 2. Кластеризация.


Для кластеризации использован алгоритм  $k$ -средних, так как он является general-purpose алгоритмом. Чтобы проверить корректность кластеризации и выбрать наиболее подходящее число кластеров, в работе использован Principal Component Analysis (PCA) [22]. Кластеризация выполняется по признакам ( $W_{i-7}$ ,  $W_{i-8}, \dots, W_{i-6-k}$ ). Затем к данным применяется PCA с переводом размерности признаков в двумерную плоскость. Точки на плоскости затем отмечаются цветами в соответствии с метками кластеров. Четкость границ между полученными кластерами показывает, насколько кластеризация выполнена корректно.

**Рис. 3** и **4** показывают полученные результаты. Изначально мы использовали 4 кластера, это количество выбрано исходя из визуального анализа результатов PCA. Но затем на этапе построения регрессионных моделей обнаружили, что три кластера дают лучший результат. Видно, что при числе используемых дней менее пяти границы между кластерами являются менее четкими. Использование более семи дней может привести к переобучению регрессионных моделей, поскольку признаков будет слишком много относительно числа дней в выборке данных.

Таким образом, на следующих этапах использованы посупочные данные за неделю и 3 или 4 кластера.



**Рис. 3. Визуализация 4-х кластеров: *a* – данные за три дня; *б* – за четыре дня; *в* – за пять дней; *г* – за семь дней (цвет означает кластер)**



**Рис. 4. Визуализация 3-х кластеров при использовании данных за семь дней**

### 3. Прогнозирование.

Поскольку используется множество разнородных факторов, в качестве базового метода построения регрессионной модели выбрана искусственная нейронная сеть (ANN). Выборка данных не настолько большая,

чтобы использовать более сложные архитектуры, такие как сверточные нейронные сети или рекуррентные. Поэтому использован многослойный перцептрон следующего вида:

- 1) входной слой;
- 2) скрытый слой из 32 нейронов с функцией активации ReLU;
- 3) скрытый слой из 16 нейронов с функцией активации ReLU;
- 4) скрытый слой из 8 нейронов с функцией активации ReLU;
- 5) выходной нейрон с сигмоидальной функцией активации.

Обучение выполняется с помощью алгоритма Adam [23]. Модель реализована с помощью Python библиотек Keras и Tensorflow.

Проведено сравнение предложенного подхода с единой нейросетевой моделью (без учета кластеров), с авторегрессионной моделью (AR), не использующей метеорологические данные, и с линейной регрессией (LR), использующей метеорологические данные. Результаты показаны в **табл. 2**. В ней представлены результаты на тестовой части выборки (10% более новых данных, а 90% более старых использованы для обучения).

Таблица 2

## Результаты прогнозных моделей с использование метеорологических данных

Модель	Число кластеров	Номер кластера	MAE	MAPE	RMSE
			МВт	%	МВт
<b>ANN</b>	-	-	<b>1,023</b>	<b>7,48</b>	<b>1,27</b>
ANN	4	1	0,653	4,73	0,81
ANN	4	2	0,779	8,16	0,97
ANN	4	3	1,495	9,60	1,68
ANN	4	4	0,905	8,81	1,34
<b>ANN</b>	<b>4</b>	<b>средневзвешенное</b>	<b>0,939</b>	<b>7,70</b>	<b>1,19</b>
ANN		1	1,067	7,15	1,40
ANN	3	2	0,734	6,13	0,92
ANN	3	3	0,776	6,90	1,00
<b>ANN</b>	<b>3</b>	<b>средневзвешенное</b>	<b>0,846</b>	<b>6,67</b>	<b>1,09</b>
<b>LR</b>	-	-	<b>0,774</b>	<b>5,82</b>	<b>0,99</b>
LR	3	1	0,604	5,03	1,04
LR	3	2	0,751	4,86	0,73
LR	3	3	0,397	3,52	0,56
<b>LR</b>	<b>3</b>	<b>средневзвешенное</b>	<b>0,586</b>	<b>4,53</b>	<b>0,77</b>
<b>AR</b>	-	-	<b>0,803</b>	<b>6,11</b>	<b>0,96</b>

Из полученных результатов сравнения моделей можно сделать следующие заключения:

– использование кластеризации по метеорологическим условиям повышает точность как для линейной регрессии, так и для искусственных нейронных сетей; снижение ошибки составило для ANN с 1,023 МВт до 0,846 МВт (17 %), для LR с 0,774 до 0,586 (24 %);

– но в то же время, если число кластеров больше оптимального, может быть обратный эффект, поскольку в каждом из кластеров окажется недостаточно данных для обучения модели;

– использование метеорологических условий снижает ошибку прогноза, разница ошибки между авторегрессионной моделью, не использующей метеорологические параметры, и лучшей моделью, использующей их, составила 0,217 МВт (27 %);

– несколько неожиданным оказалось существенное преимущество линейной регрессии над нейросетевыми моделями.

Последний пункт можно объяснить двумя фактами:

1) использование признаков, полученных с помощью PCA, в качестве дополнительных входных признаков позволило во многом выполнить агрегирование метеорологических факторов еще до применения регрессионных моделей;

2) объем данных недостаточно велик для эффективного применения нейронных сетей, для их более эффективной работы, вероятно, требуются данные за период 10-20 лет.

Нужно подчеркнуть, что полученный результат позволяет создать надежную и очень простую модель на базе машинного обучения с минимальным использованием сложных и слабоконтролируемых методов машинного обучения.

Итоговая модель выглядит следующим образом.

1. На этапе построения прогнозной системы выполняется:

1) кластеризация алгоритмом k-means на три кластера;

2) применение PCA для формирования двух наиболее значимых признаков, агрегирующих метеорологические параметры;

3) построение для каждого кластера своей линейной регрессионной модели.

2. На этапе эксплуатации выполняется:

1) определение, к какому кластеру относятся текущие условия по данным метеорологических наблюдений в течение предыдущей недели;

2) применение PCA для получения агрегированных признаков;

3) применение линейной регрессионной модели для получения прогноза потребления.

На рис. 5 показано сопоставление истинного графика нагрузки и прогнозного для фрагмента тестовой выборки.




Рис. 5. Сравнение истинного и прогнозного графиков электропотребления

## ЗАКЛЮЧЕНИЕ

В работе использованы посutoчные данные за 2015-2020 гг. (ноябрь-март). Чтобы повысить точность прогнозирования электропотребления, в работе использованы метеорологические факторы и кластеризация условий. Использованы только ретроспективные данные, чтобы исключить зависимость от метеорологических прогнозов. На этапе предобработки данных применен метод разложения пространства признаков на главные компоненты, который, во-первых, позволяет проверить корректность кластеризации, во-вторых, агрегировать метеорологические признаки. Далее кластеризация позволяет сделать вместо одной модели, учитывающей все возможные условия работы энергосистемы, несколько более простых и более точных моделей. За счет кластеризации и PCA удалось при использовании линейных моделей получить более высокую точность, чем при использовании единой нейросетевой модели. Снижение MAE за счет кластеризации составило 0,19 МВт (MAE снижено на 24 %). Использование метеорологических условий позволило снизить ошибку прогноза на 0,22 МВт (27 %).

В результате средняя ошибка прогноза на тестовой части выборки данных составила 0,59 МВт, среднеквадратическая ошибка 0,77 МВт, средняя ошибка в процентах 4,5% по сравнению с авторегрессионной моделью без кластеризации и учета метеорологических факторов (MAE 0,80 МВт, RMSE 0,96 МВт, MAPE 6,11 %).

В дальнейшем планируется разработать модель более точной оценки снижения потребления ископаемого топлива за счет повышения точности прогнозирования нагрузки. А также исследовать возможность использования накопителей энергии для повышения гибкости управления электроэнергетической системой.

**Исследование выполнено при финансовой поддержке в рамках реализации программы развития НГТУ, научный проект №C22-15.**

## Список источников

1. Medium term load forecasting for jordan electric power system using particle swarm optimization algorithm based on least square regression methods / M. Hattab, M. Ma'itah, T. Sweidan, M. Rifai // J. of Power and Energy Engineering. 2017. Vol. 5. Pp. 75-96. doi: 10.4236/jpee.2017.52005
2. Electricity load forecasting: a systematic review / I.K. Nti, M. Teimeh, O. Nyarko-Boateng, A. F. Adekoya // J. of Electrical Systems and Inf. Technol. 2020. Vol. 7(13). doi: 10.1186/s43067-020-00021-8
3. Abu-Shikhah N., Elkarmi F., Aloquili O. Medium-term electric load forecasting using multivariable linear and non-linear regression // Smart Grid and Ren. Energy. 2011. Vol. 2(2). Pp. 126-135. doi: 10.4236/sgre.2011.22015
4. Hahn H., Meyer-Nieberg S., Pickl S. Electric load forecasting methods: Tools for decision making // European J. of Operational Research. 2009. Vol. 199(3). Pp. 902-907. doi: 10.1016/j.ejor.2009.01.062
5. Borges C.E., Penya Y.K., Fenandez I. Evaluating combined load forecasting in large power system and smart grids // IEEE Transactions on Industrial Informatics. 2013. Vol. 9(3). Pp. 1570-1577. doi: 10.1109/TII.2012.2219063
6. Short-term power load forecasting, profile identification, and customer segmentation: a methodology based on periodic time series / M. Espinoza, C. Joye, R. Belmans, B. De Moor // IEEE Transactions on Power Systems. 2005. Vol. 20(3). Pp. 1622-1630. doi: 10.1109/TPWRS.2005.852123
7. Blind kalman filtering for short-term power load forecasting / S. Sharma, A. Majumdar, V. Elvira, É. Chouzenoux // IEEE Transactions on Power Systems. 2020. Vol. 35(6). Pp. 4916-4919. doi: 10.1109/TPWRS.2020.3018623
8. Arora S., Taylor J.W. Short-term forecasting of anomalous load using rule-based triple seasonal methods // IEEE Transactions on Power Systems. 2013. Vol. 28(3). Pp. 3235-3242. doi: 10.1109/TPWRS.2013.2252929
9. Multi-scale convolutional neural network with time-cognition for multi-step short-term power load forecasting / Z. Deng, B. Wang, Y. Xu, T. Xu // IEEE Access. 2019. Vol. 7. Pp. 88058-88071. doi: 10.1109/ACCESS.2019.2926137
10. Chen B.-J., Chang M.-W., Lin Ch.-J. Load forecasting using support vector machines: a study on EUNITE competition 2001 // IEEE Transactions on Power Systems. 2004. Vol. 19(4). Pp. 1821-1830. doi: 10.1109/TPWRS.2004.835679
11. A short-term power load forecasting method using integrated CNN and LSTM network / S.H. Rafi, Nahid-Al-Masood, S.R. Deeba, E. Hossain // IEEE Access. 2021. Vol. 51. Pp. 32436-32448. doi: 10.1109/ACCESS.2021.3060654
12. The impact of data filtration on the accuracy of multiple time-domain forecasting for photovoltaic power plants generation / S.A. Eroshenko, A.I. Khalyasmaa, D.A. Snegirev, V.V. Dubailova // Applied Sciences. 2020. Vol. 10(22). Art. 8265. doi: 10.3390/app10228265
13. Panapakidis I.P., Christoforidis G.C. Implementation of modified versions of the K-means algorithm in power load curves profiling // Sustainable Cities and Society. 2017. Vol. 35. Pp. 83-93. doi: 10.1016/j.scs.2017.08.002
14. Viola L.G. Clustering electricity usage profiles with K-means. URL: <https://towardsdatascience.com/clustering-electricity-profiles-with-k-means-42d6d0644d00> (дата обращения 15.09.2022).
15. Гуломзода А.Х., Сафаралиев М.Х., Люханов Е.А. Модифицированный способ синхронизации Microgrid с внешней изолированной энергосистемой // Электротехнические системы и комплексы. 2021. № 3(52). С. 72-80. doi: 10.18503/2311-8318-2021-3(52)-72-80
16. Разработка моделей среднесрочного прогнозирования электропотребления в изолированно работающих энергосистемах на основе ансамблевых методов машинного обучения / С.М. Асанова, Дж.С. Ахьеев, С.А. Дмитриев, П.В. Матренин // Известия НТЦ единой энергетической системы. 2021. №1 (84). С. 32-39.
17. Адаптивные ансамблевые модели для среднесрочного прогнозирования выработки электроэнергии гидроэлектростанциями в изолированных энергосистемах с учётом изменений температуры / М.Х. Сафаралиев, П.В. Матренин, С.А. Дмитриев, Дж.С. Ахьеев // Электротехнические системы и комплексы. 2022. 1(54). С. 38-45. doi: 10.18503/2311-8318-2022-1(54)-38-45
18. Разработка моделей среднесрочного прогнозирования притока воды для планирования выработки электроэнергии в изолированных энергосистемах / М.Х. Сафаралиев, С.Е. Кокин, С.А. Дмитриев, П.В. Матренин // Электричество. 2022. № 5. С. 58-68. doi: 10.24160/0013-5380-2022-5-58-68
19. Khalyasmaa A.I., Matrenin P.V., Eroshenko S.A. Inappropriate machine learning application in real power industry cases // International Journal of Electrical and Computer Engineering. 2022. Vol. 12(3). Pp. 3023-3032. doi: 10.11591/ijece.v12i3.pp 3023-3032
20. Improving accuracy and generalization performance of small-size recurrent neural networks applied to short-term load forecasting / P.V. Matrenin, V.Z. Manusov, A.I. Khalyasmaa, D.V. Antonenkov // Mathematics. 2020. Vol. 8(12). Art. 2169. doi: 10.3390/math8122169
21. Hartigan J.A., Wong M.A. Algorithm AS 136: A K-Means clustering algorithm // Journal of the Royal Statistical Society. Series C (Applied Statistics). 1979. Vol. 28(1). Pp. 100-108. doi: 10.2307/2346830

22. Principal manifolds for data visualization and dimension reduction / Gorban A.N., Kegl B., Wunsch D.C., Zinov'yev A. Berlin: Springer, 2008. 361 p.

Поступила в редакцию 20 сентября 2022 г.

23. Kingma D.P., Ba J.L. Adam: A method for stochastic optimization. URL: <https://arxiv.org/pdf/1412.6980.pdf> (дата обращения 12.09.2022).

Принята к печати 13 октября 2022 г.

## INFORMATION IN ENGLISH

### MEDIUM-TERM FORECASTING OF POWER CONSUMPTION BASED ON AN ARTIFICIAL NEURAL NETWORK IN ISOLATED POWER SYSTEMS

Murodbek Kh. Safaraliev

Postgraduate Student, Research Engineer, Department of Automated Electrical Systems, Ural Federal University, Ural Power Engineering Institute, Yekaterinburg, Russia, murodbek\_03@mail.ru, <https://orcid.org/0000-0003-3433-9742>

Pavel V. Matrenin

Ph.D. (Engineering), Associate Professor, Department of Industrial Power Supply Systems, Novosibirsk State Technical University, Novosibirsk, Russia, matrenin.2012@corp.nstu.ru, <https://orcid.org/0000-0001-5704-0976>

Natalya G. Kyrianova

Teaching Assistant, Department of Automated Power Systems, Novosibirsk State Technical University, Novosibirsk, Russia, kyrianova.2010@corp.nstu.ru, <https://orcid.org/0000-0003-3145-8869>

Anvari H. Ghulomzoda

Postgraduate Student, Department of Automated Electric Power Systems, Novosibirsk State Technical University, Novosibirsk, Russia, anvar\_4301@mail.ru, <https://orcid.org/0000-0002-4344-6462>

In the conditions of sharply variable highland climatic conditions, territorial distribution, generating capacity shortage, high cost of carbon fuel and the absence of large energy storage facilities to cover peak loads, it is necessary to ensure balance reliability in mountain isolated power systems (IES), taking into account the optimal resources allocation. To ensure the required balance reliability, it is necessary to implement reliable forecasting of power consumption in the medium term for planning the generating equipment load, taking into account the necessary and sufficient load coverage, generation costs, environmental friendliness and other criteria. Therefore, increased requirements are placed on the accuracy and robustness of the load forecast. A study of the meteorological factors influence on the medium-term forecasting of electricity consumption at the power plant in the Gorno-Badakhshan Autonomous Oblast (GBAO), located in the Republic of Tajikistan, which is characterized by the above-mentioned specific properties. A neural network model was used to predict power consumption taking into account meteorological factors. In order to increase the effectiveness of model training, an approach based on clustering of meteorological conditions is proposed. Its own neural network model is created for each cluster, in addition, an auxiliary model has been trained, which relates the current conditions to one of the clusters. Thus, instead of a single model that would take into account all possible conditions, a system of much simpler models was created, which increases the interpretability of the forecasting procedure and reduces the risk of retraining.

**Keywords:** medium-term forecasting of power consumption, adaptive machine learning models, meteorological conditions, isolated power system, clustering

#### REFERENCES

- Hattab M., Ma'itah M., Sweidan T., Rifai M. Medium Term Load Forecasting for Jordan Electric Power System Using Particle Swarm Optimization Algorithm Based on Least Square Regression Methods. *J. of Power and Energy Engineering*. 2017, vol. 5, Pp. 75-96. doi: 10.4236/jpee.2017.52005
- Nti I.K., Teimeh M., Nyarko-Boateng O., Adekoya A.F. Electricity load forecasting: a systematic review. *J. of Electrical Systems and Inf. Technol.* 2020, vol. 7(13). doi: 10.1186/s43067-020-00021-8
- Abu-Shikhah N., Elkarmi F., Aloquili O. Medium-Term Electric Load Forecasting Using Multivariable Linear and Non-Linear Regression. *Smart Grid and Ren. Energy*. 2011, vol. 2, pp. 126-135. doi: 10.4236/sgre.2011.22015
- Hahn H., Meyer-Nieberg S., Pickl S. Electric load forecasting methods: Tools for decision making. *European J. of Operational Research*. 2009, vol. 199, pp. 902-907. doi: 10.1016/j.ejor.2009.01.062
- Borges C.E., Penya Y.K., Fenandez I. Evaluating combined load forecasting in large power system and smart grids. *IEEE Transactions on Industrial Informatics*. 2013, vol. 9(3), pp. 1570-1577. doi: 10.1109/TII.2012.2219063
- Espinoza M., Joye C., Belmans R., De Moor B. Short-term power load forecasting, profile identification, and customer segmentation: a methodology based on periodic time series. *IEEE Transactions on Power Systems*. 2005, vol. 20(3), pp. 1622-1630. doi: 10.1109/TPWRS.2005.852123
- Sharma S., Majumdar A., Elvira V., Chouzenoux É. Blind kalman filtering for short-term power load forecasting. *IEEE Transactions on Power Systems*. 2020, vol. 35(6), pp. 4916-4919. doi: 10.1109/TPWRS.2020.3018623
- Arora S., Taylor J.W. Short-term forecasting of anomalous load using rule-based triple seasonal methods. *IEEE Transactions on Power Systems*. 2013, vol. 28(3), pp. 3235-3242. doi: 10.1109/TPWRS.2013.2252929
- Deng Z., Wang B., Xu Y., Xu T. Multi-scale convolutional neural network with time-cognition for multi-step short-term power load forecasting. *IEEE Access*. 2019, vol. 7, pp. 88058-88071. doi: 10.1109/ACCESS.2019.2926137
- Chen B.-J., Chang M.-W., Lin Ch.-J. Load forecasting using support vector machines: a study on EUNITE competition 2001. *IEEE Transactions on Power Systems*. 2004, vol. 19(4), pp. 1821-1830. doi: 10.1109/TPWRS.2004.835679
- Rafi S.H., Nahid-Al-Masood, Deeba S.R., Hossain E. A short-term power load forecasting method using integrated CNN and LSTM network. *IEEE Access*. 2021, vol. 51, pp. 32436-32448. doi: 10.1109/ACCESS.2021.3060654

12. Eroshenko S.A., Khalyasmaa A.I., Snegirev D.A., Dubailova V.V. The impact of data filtration on the accuracy of multiple time-domain forecasting for photovoltaic power plants generation. *Applied Sciences*. 2020, vol. 10(22). Art. 8265. doi: 10.3390/app10228265
13. Panapakidis I.P., Christoforidis G.C. Implementation of modified versions of the K-means algorithm in power load curves profiling. *Sustainable Cities and Society*. 2017, vol. 35, pp. 83-93. doi: 10.1016/j.scs.2017.08.002
14. Viola L.G. Clustering electricity usage profiles with K-means. URL: <https://towardsdatascience.com/clustering-electricity-profiles-with-k-means-42d6d0644d00> (accessed 15 September 2022)
15. Ghulomzoda A.H., Safaraliev M.Kh., Lyukhanov E.A. Modified method for synchronizing Microgrid with an external isolated power system. *Elektrotehnicheskie sistemy i kompleksy* [Electrotechnical systems and complexes], 2021, no. 3(45), pp. 72-80. (In Russian)
16. Asanova S.M., Ahyoev J.S., Dmitriev S.A., Matrenin P.V. Development of models for power consumption medium-term forecasting in isolated power systems based on ensemble methods of machine learning. *Izvestija NTC EDINOJ ENERGETICHESKOJ SISTEMY* [Proceedings of the STC of UNIFIED ENERGY SYSTEM], 2021, no. 1(84), pp. 32-39. (In Russian)
17. Safaraliev M.Kh., Matrenin P.V., Dmitriev S.A., Ahyoev J.S. Adaptive ensemble models for medium-term forecasting of power generation by hydropower plants in isolated power systems taking into account temperature changes. *El-*
- ektrotehnicheskie sistemy i kompleksy* [Electrotechnical systems and complexes], 2022, no. 1(54), pp. 38-45. (In Russian). doi: 10.18503/2311-8318-2022-1(54)-38-45
18. Safaraliev M.Kh., Kokin S.E., Dmitriev S.A., Matrenin P.V. Development of medium-term water inflow forecasting models for planning electricity generation in isolated power systems. *Elektrичество* [Electricity], 2022, no.5, pp. 58-68. (In Russian). doi: 10.24160/0013-5380-2022-5-58-68
19. Khalyasmaa A.I., Matrenin P.V., Eroshenko S.A. Inappropriate machine learning application in real power industry cases. *International Journal of Electrical and Computer Engineering*. 2022, vol. 12(3), pp. 3023-3032. doi: 10.11591/ijece.v12i3.pp 3023-3032
20. Matrenin P.V., Manusov V.Z., Khalyasmaa A.I., Antonenkov D.V. Improving accuracy and generalization performance of small-size recurrent neural networks applied to short-term load forecasting. *Mathematics*. 2020, vol. 8(12), Art. 2169. doi: 10.3390/math8122169
21. Hartigan J.A., Wong M.A. Algorithm AS 136: A K-Means Clustering Algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*. 1979, vol. 28(1), pp. 100-108. doi: 10.2307/2346830
22. Gorban A.N., Kegl B., Wunsch D.C., Zinovyev A. Principal Manifolds for Data Visualization and Dimension Reduction. Springer, 2008. 361 p.
23. Kingma D.P., Ba J.L. Adam: A method for stochastic optimization. URL: <https://arxiv.org/pdf/1412.6980.pdf> (accessed 12 September 2022)

Среднесрочное прогнозирование электропотребления на основе искусственной нейронной сети в изолированных энергосистемах / М.Х. Сафаралиев, П.В. Матренин, Н.Г. Кирьянова, А.Х. Гуломзода // Электротехнические системы и комплексы. 2022. № 4(57). С. 4-11. [https://doi.org/10.18503/2311-8318-2022-4\(57\)-4-11](https://doi.org/10.18503/2311-8318-2022-4(57)-4-11)

Safaraliev M.Kh., Matrenin P.V., Kyrianova N.G., Ghulomzoda A.H. Medium-Term Forecasting of Power Consumption Based on an Artificial Neural Network in Isolated Power Systems. *Elektrotehnicheskie sistemy i kompleksy* [Electrotechnical Systems and Complexes], 2022, no. 4(57), pp. 4-11. (In Russian). [https://doi.org/10.18503/2311-8318-2022-4\(57\)-4-11](https://doi.org/10.18503/2311-8318-2022-4(57)-4-11)