

¹ Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, г. Екатеринбург² Новосибирский государственный технический университет³ Таджикский технический университет имени академика М.С. Осими, г. Душанбе, Республика Таджикистан

АДАПТИВНЫЕ АНСАМБЛЕВЫЕ МОДЕЛИ ДЛЯ СРЕДНЕСРОЧНОГО ПРОГНОЗИРОВАНИЯ ВЫРАБОТКИ ЭЛЕКТРОЭНЕРГИИ ГИДРОЭЛЕКТРОСТАНЦИЯМИ В ИЗОЛИРОВАННЫХ ЭНЕРГОСИСТЕМАХ С УЧЁТОМ ИЗМЕНЕНИЙ ТЕМПЕРАТУРЫ

В статье выполнен анализ взаимосвязи между выработкой электроэнергии на гидроэлектростанциях (ГЭС) и изменениями температуры для среднесрочного прогнозирования в изолированной энергосистеме Горно-Бадахшанской автономной области (ГБАО) Республики Таджикистан. Повышение точности прогнозирования позволит решить проблему контроля расхода воды, а также оптимизировать выработку электроэнергии на ГЭС с обеспечением надёжного функционирования энергосистемы. Решение подобных задач связано с рядом проблем, таких как отсутствие достаточного объема данных, неопределенность выработки электроэнергии, отсутствие регулярности работы одной станции и недостаточная точность используемых на ГЭС моделей прогнозирования. При среднесрочном прогнозировании выработки электроэнергии на ГЭС следует учитывать сезонность изменений стока и притока воды, особенно в энергосистемах с высокой долей возобновляемых источников энергии, где изменение температуры напрямую влияет на запасы и возможность регулирования. В работе рассматривается проблема построения модели среднесрочного прогнозирования выработки электроэнергии на ГЭС с учетом изменений температуры в изолированных энергосистемах. В качестве метода среднесрочного прогнозирования выработки электроэнергии был выбран подход машинного обучения, который характеризуется высокой степенью адаптации к изменениям условий работы. Проведено сравнительное исследование таких моделей, как линейная/полиномиальная регрессия с регуляризацией Тихонова, алгоритм k-ближайших соседей, адаптивный бустинг деревьев решений, адаптивный бустинг линейных моделей, случайный лес, экстремальный градиентный бустинг, многослойный перцептрон. В результате выполнения компьютерного моделирования обоснована целесообразность применения модели на базе адаптивного бустинга с линейной регрессией (ABLR).

Ключевые слова: ансамблевые модели, среднесрочное прогнозирование, гидроэлектростанция, выработка электроэнергии, изолированная энергосистема, температура.

ВВЕДЕНИЕ

Гидроэнергетика на сегодняшний день остается наиболее важной из возобновляемых источников энергии для производства электроэнергии во всем мире, обеспечивая 19% электроэнергии планеты [1, 2]. Малая гидроэлектростанция (МГЭС) в большинстве случаев является «речной», без плотины или водохранилища и является одной из наиболее экономически эффективных и экологически безопасных энергетических технологий, которые следует рассматривать для электроснабжения сельских районов в менее экономически развитых странах [3-6].

Точное и надежное прогнозирование выработки электроэнергии ГЭС имеет важное значение для управления и планирования гидрогенерации. Ввиду бурного развития распределенной генерации возникает нехватка исторических данных о производстве электроэнергии, что затрудняет разработку прогнозных моделей. Задача прогнозирования выработки электроэнергии на ГЭС считается одной из самых сложных задач в области интеллектуального анализа данных, требующей комплексного анализа больших объемов данных с учетом влияния на электропотребление множественных взаимосвязей и динамических процессов.

Среднесрочное прогнозирование выработки электроэнергии для каждого вида возобновляемых источников

является ключевым вопросом для энергосистемы, поскольку такое прогнозирование является базовым инструментом для обеспечения надежного электроснабжения, планирования резерва мощности, организации обслуживания и ремонта и ведения режима. Для собственников возобновляемых источников среднесрочное прогнозирование имеет решающее значение для определения модели поведения на рынке электроэнергии, планирования задач по техническому обслуживанию и формирования плановых показателей с горизонтом в одну неделю.

Большинство опубликованных работ, направленных на разработку моделей среднесрочного прогнозирования и связанных с вопросами гидроэнергетики, ориентировано на управление водными ресурсами на базе прогнозных данных только о притоке в водохранилища [7, 8] или с учетом информации о стоке и притоке [9-11]. Ряд исследований направлен на оценку мощности и планирования выработки для мини-ГЭС [12], малых ГЭС [13], а также крупных ГЭС [14]. Применяемые модели среднесрочного (на неделю вперед) прогнозирования выработки электроэнергии не учитывают климатических изменений. Для среднесрочного прогнозирования может быть применено множество различных методов, от простейших регрессионных моделей до глубоких рекуррентных нейронных сетей. При этом кроме выбора модели необходимо выполнять анализ исходных и предобработку данных, а также отбор признаков.

В данной работе рассмотрен подход по использованию компактных моделей на базе машинного обучения

для среднесрочного прогнозирования выработки электроэнергии гидроэлектростанциями с учётом изменений температуры, отличием которого является полная автономность и автоматизация обучения и исключение риска переобучения. Настройка гиперпараметров модели может быть выполнена автоматизировано с применением случайного поиска или поиска по сетке.

ПОСТАНОВКА ЗАДАЧИ И ИСХОДНЫЕ ДАННЫЕ

Исследуемым объектом является изолированная энергосистема Горно-Бадахшанской автономной области – региона Республики Таджикистан. Изолированной энергосистемой ГБАО управляет компания Ramig Energy, на балансе которой находится 11 ГЭС общей мощностью 43,5 МВт. На сегодняшний день изолированная энергосистема ГБАО испытывает серьезные трудности, связанные с устойчивым дефицитом электроэнергии в зимний период с ноября по март. Основными причинами дефицита электроэнергии в изолированной энергосистеме ГБАО являются следующие [15-17]:

- изолированная работа энергосистемы;
- ограниченность стока воды в реках в зимнем (меженном) периоде;
- отсутствие сезонных накопителей энергии (водохранилищ);
- рост потребления электрической энергии населением в зимнем отопительном периоде.

Задача прогнозирования в данной работе сформулирована следующим образом. Построение модели, выполняющей преобразование входных данных (признаков) X в прогноз вырабатываемой за сутки электроэнергии мощностей генерации на неделю (7 дней) вперед E^* :

$$E^* = f(X). \quad (1)$$

Показателем точности прогноза в данной работе выбран средний модуль процента ошибки (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{E_i^* - E_i}{E_i} \right|, \quad (2)$$

где n – число дней в выборке; E_i^* – прогнозное значение генерируемой электроэнергии в i -е сутки; E_i – истинное значение в i -е сутки.

Используемый набор данных содержит суточные значения вырабатываемой электроэнергии (изолированная энергосистема ГБАО) с ноября по март включительно за 5 лет (2015–2019) и среднесуточные температуры, данные за 765 суток. Для обработки данных номера месяцев были преобразованы следующим образом: ноябрь – 1, декабрь – 2, март – 5. Отсчет лет начинается с 2015 года, так что номера годов преобразованы к диапазону 1–5. На рис. 1 приведены графики за один и тот же месяц (январь).




Рис. 1. Фрагмент выборки данных (январь 2015–2019 годов)

Перед построением модели прогнозирования необходимо провести оценку и отбор наиболее значимых признаков, что может существенно повлиять на процесс обучения моделей на базе машинного обучения [18]. Помимо календарных данных (год, месяц и число месяца), для прогноза необходимо использовать ретроспективные данные генерации. Также в работе проверяется гипотеза о влиянии среднесуточной температуры на точность прогноза.

На рис. 2 показана матрица, состоящая из коэффициентов корреляции Пирсона, для факторов, которые могут быть использованы при прогнозировании. Кроме них, используются ретроспективные данные выработки электроэнергии в предыдущие дни. Видно, что из метеорологических факторов существенное влияние оказывает среднесуточная температура (коэффициент 0,357), кроме того, явно наблюдается изменение год от года (коэффициент 0,38).

Сформированная структура выборки данных для построения регрессионных моделей показана в табл. 1, где m – длина используемого временного ряда ретроспективных значений. Если используется неделя, то $m = 7$, две недели – 14 и т.д. Например, если $m = 7$ и дается прогноз на 26 января, то для формирования прогноза будут использованы ретроспективные данные с 19 (E_{i-7} , $26 - 7 = 19$) по 13 (E_{i-13} , $26 - [7 + m - 1] = 13$) января включительно.

Число записей в выборке зависит от m , так как для первых $m + 7$ дней начального месяца (января) нет нужного количества ретроспективных данных. Выборка делится на обучающую-валидационную и тестовую в пропорции 4 к 1 (в данном случае в тестовую выборку попадает последний год всей выборки). Нужно отметить, что выборка не перемешивалась, так что тестирование было проведено в условиях, соответствующих реальным, когда модель обучается на ретроспективных данных, а затем используется в будущем на новых данных.

В табл. 2 приведены размеры выборок при разных значениях m .

	день	месяц	год	температура	влажность	скорость ветра	выработка
день	1,00	0,0	0,01	0,03	0,05	0,00	0,00
месяц	0,01	1,00	0,00	0,43	0,48	0,09	-0,18
год	0,00	0,00	1,00	-0,10	0,10	-0,26	0,38
температура	0,03	0,43	-0,10	1,00	-0,32	0,27	0,36
влажность	0,05	-0,48	0,10	-0,32	1,00	-0,20	0,00
скорость ветра	0,00	0,09	-0,26	0,27	-0,20	1,00	0,04
выработка	0,00	-0,18	0,38	0,36	0,00	0,04	1,00

Рис. 2. Матрица коэффициентов корреляции

Таблица 1
Структура выборки для применения машинного обучения и пример заполнения

День	Месяц	Год	Темп-ра, C°	E_{i-7} , млн кВтч	...	$E_{i-(m+7-1)}$, млн кВтч	E_i , млн кВтч (прогнозируемое значение)
26	3	2	-3,2	0,687	...	0,782	0,724

Таблица 2
Размеры выборок при разных интервалах используемых ретроспективных данных

m	Число столбцов	Число строк в обучающей выборке	Число строк в валидационной выборке	Число строк в тестовой выборке
7	11	576	110	137
14	18	547	104	130
21	25	518	98	123

ИСПОЛЬЗУЕМЫЕ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ

Модели, подбираемые гиперпараметры и диапазоны их значений приведены в **табл. 3**.

В **табл. 3** использованы следующие обозначения:

- LR – линейная / полиномиальная регрессия с регуляризацией Тихонова;
- kNN – k-ближайших соседей;
- ABDT – адаптивный бустинг деревьев решений;
- ABLR – адаптивный бустинг линейных моделей;
- RF – случайный лес;
- XGB – экстремальный градиентный бустинг;
- MLP – многослойный перцептрон.

Таблица 3
Результаты подбора гиперпараметров примененных моделей машинного обучения

Модель	Гипер-параметр	Минимальное значение	Максимальное значение	Шаг	Подобранное значение
LR	Степень полинома	1	3	1	1
kNN	Число ближайших соседей k	2	8	1	2
ABDT	Число базовых моделей	10	50	1	14
	Глубина деревьев	2	6	1	3
	Минимальное число точек данных для ветвления	2	8	1	3
ABLR	Число базовых моделей	2	10	1	2
RF	Число базовых моделей	10	50	1	37
	Глубина деревьев	2	10	1	5
	Минимальное число точек данных для ветвления	2	8	1	2
XGB	Число базовых моделей	10	50	1	29
	Глубина деревьев	2	10	1	4
	Скорость обучения	0,01	0,5	0,05	0,3
MLP	Число нейронов первого скрытого слоя	10	200	10	90
	Число нейронов второго скрытого слоя	10	100	10	80

Для настройки гиперпараметров модели был применен случайный поиск (Random Search). Подбор гиперпараметров выполнялся при m , равном 14. Программные реализации моделей, кроме XGBoost [19], взяты из открытой библиотеки Scikit-Learn [20]. Для не приведенных в **табл. 3** гиперпараметров использованы значения по умолчанию из указанных источников.

Для всех моделей был проведен анализ влияния длины используемого временного ряда предыдущих значений генерации и влияние температуры на точность прогнозов.

РЕЗУЛЬТАТЫ

Результаты моделей при различных вариантах используемых входных признаков на тестовой выборке приведены в **табл. 4** и на **рис. 3**.

Из полученных результатов можно сделать следующие заключения:

1. Ансамбли деревьев решений, то есть модели с дискретным (кусочно-постоянным) выходом, уступают моделям с непрерывным выходом на 2-5 процентных пункта.

2. Для моделей с использованием линейной регрессии (LR и ABLR) увеличение интервала используемых ретроспективных данных несколько снижает ошибку, можно предположить, что за счет более точного определения тренда.

3. Наилучшая точность получена при использовании адаптивного бустинга с линейной регрессией в качестве базовой модели, что совпадает с результатами, полученными ранее для прогнозирования электропотребления данной системы [17].

4. Существенное снижение точности моделей при использовании метеорологических данных является несколько неожиданным результатом, который требует дополнительного анализа. Вероятно, изменение климата год от года приводит к изменению зависимостей между генерацией и температурой, так что модель, обученная на данных первых четырех лет, находит зависимости между температурой и генерацией, которые на следующий год оказываются измененными.




Рис. 3. Сравнение результатов моделей

Таблица 4
Сравнение результатов моделей

Модель	Без использования температуры			С использованием температуры			
	m	7	14	21	7	14	21
LR		5,99	6,20	5,76	6,53	7,15	7,19
kNN		7,83	7,90	7,99	13,41	14,12	13,35
ABDT		10,52	10,00	9,80	10,78	10,35	10,01
ABLR		5,82	5,78	5,23	6,25	7,30	6,98
RF		8,21	7,87	7,93	8,29	8,13	7,72
XGB		9,61	9,83	10,71	10,84	11,80	12,76
MLP		5,70	5,71	5,70	8,69	9,86	10,12

Это подтверждается визуализацией, показанной на рис. 4-6. Их анализ показывает, что зависимости генерации от температуры существенно отличаются из года в год. Даже коэффициенты корреляции существенно отличаются, в 2015 году коэффициент корреляции Пирсона между генерацией и температурой составлял 0,38, в 2019 году – 0,77, то есть в 2019 году температура оказывала существенно большее влияние на генерацию. Поэтому при обучении модели на ретроспективных данных она выделяет определенные зависимости, которые затем перестают работать из-за указанных выше причин.

Кроме того, из правой части рис. 6, б видно, что 2019 год, который попал в тестовую выборку, в принципе характеризуется большим значением генерации, чем предыдущие 4 года, особенно при температурах выше 0°C.

Сопоставление прогноза, полученного наилучшей для задачи моделью (Адаптивный бустинг линейных регрессий с регуляризацией Тихонова), показано на рис. 7. Средняя ошибка на тестовой выборке составила 5,23% или 44 МВт·ч при средней суточной генерации 718 МВт·ч.

Регуляризация Тихонова (L2-регуляризация) может быть записана следующим образом:

$$w^* = \arg \min_w \left(\sum_{i=1}^n (y_i - (wX_i - b))^2 + \lambda \|w\|_2^2 \right). \quad (3)$$

В выражении (3) w , b – коэффициенты регрессии, $\|w\|_2^2$ – квадрат Евклидова расстояния или сумма квадратов всех элементов вектора w .

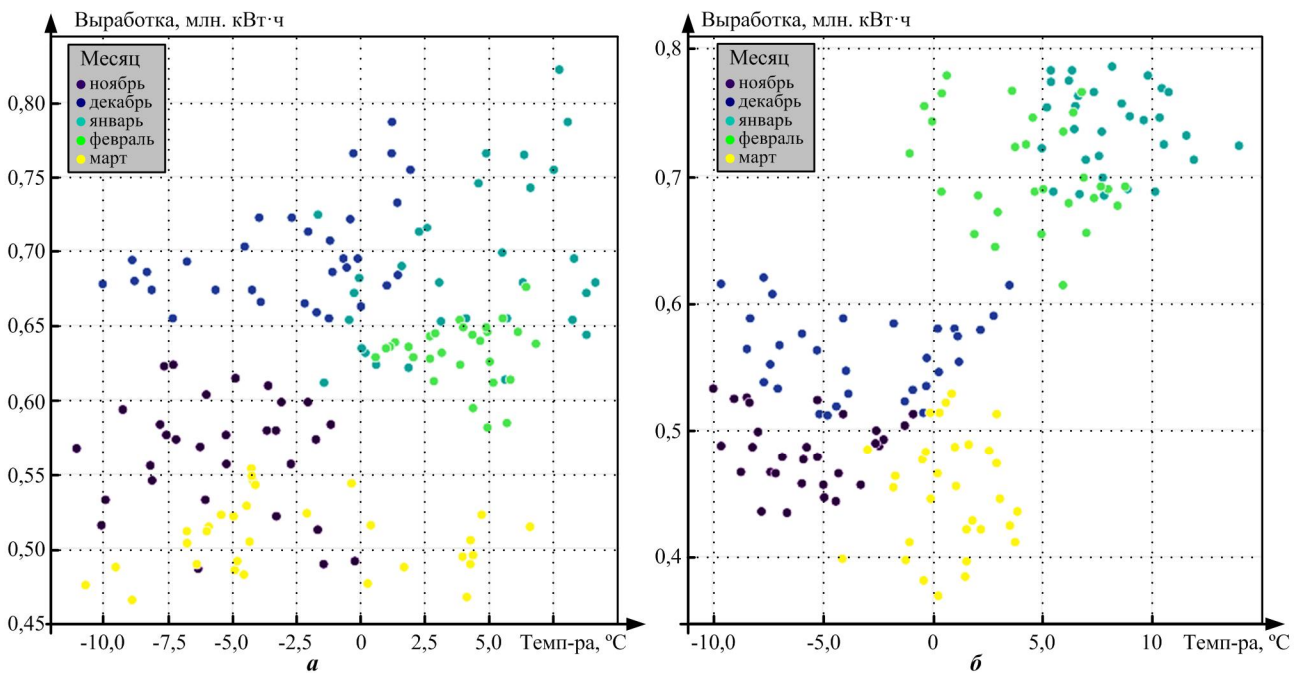


Рис. 4. Распределение дней по генерации и температуре: а – 2015 год, б – 2016 год

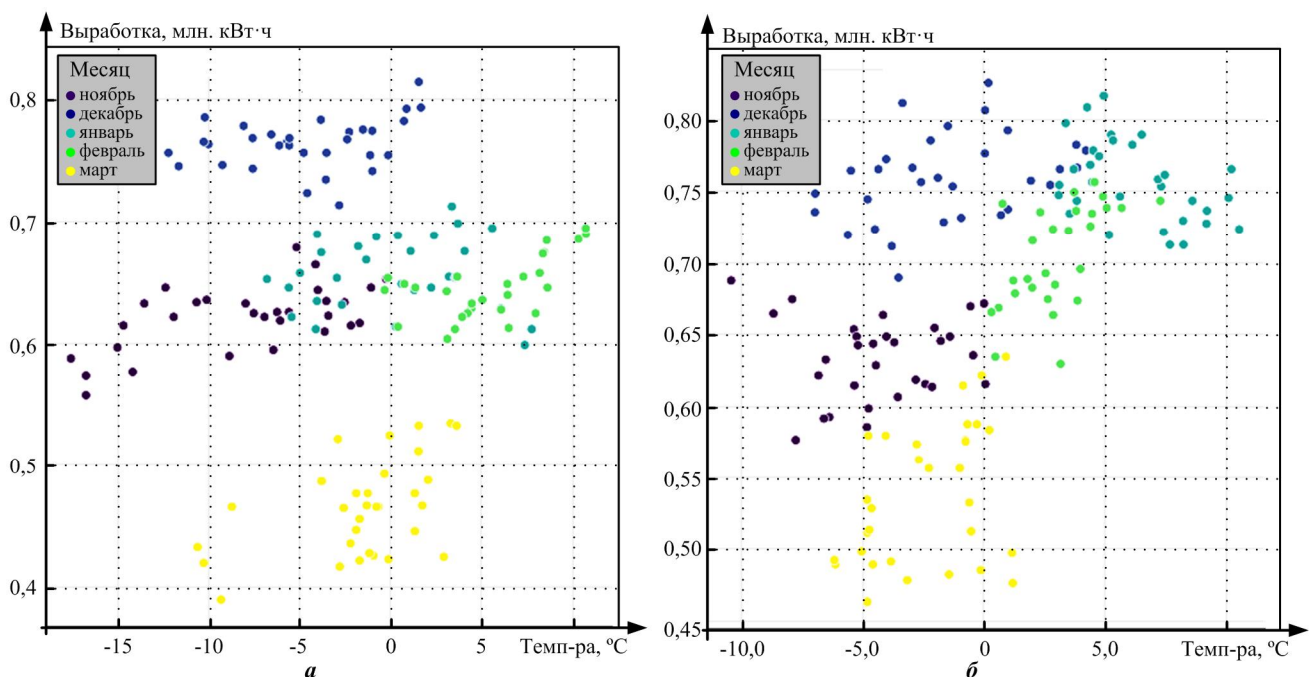


Рис. 5. Распределение дней по генерации и температуре: а – 2017 год, б – 2018 год




Рис. 6. Распределение дней по генерации и температуре: а – 2019 год, б – 2015-2019 годы




Рис. 7. Сопоставление прогнозов и истинных значений мощности, 2019 год (тестовая часть выборки)

Поскольку модель адаптивного бустинга представляет собой линейную взвешенную сумму базовых моделей, то итоговая ансамблевая модель, объединяющая 4 линейные регрессии, может быть после завершения обучения свернута с линейную форму:

$$Y^* = f(X) = AX + b;$$

$$y_i^* = f(x_i) = a_1 year_i + a_2 month_i + a_3 day_i + a_4 E_{7,i} + a_5 E_{8,i} + \dots + a_{25} E_{28,i} + b.$$

ЗАКЛЮЧЕНИЕ

В данной работе основное внимание уделяется разработке модели среднесрочного прогнозирования выработки электроэнергии гидроэлектростанции на неделю вперед в изолированных энергосистемах с высокой долей ГЭС. Выполнен анализ семи различных моделей машинного обучения для прогнозирования выработки гидроэлектростанций на основе ретроспективных данных о генерации и метеорологических параметров. Наилучший результат был получен при ис-

пользовании адаптивного бустинга с линейной регрессией в качестве базовой модели.

Полученные результаты с высокой степенью достоверности позволяют сделать вывод, что ансамблевые методы машинного обучения являются приемлемым решением для среднесрочного прогнозирования выработки электроэнергии гидроэлектростанциями в условиях изменения температуры. Предлагаемый метод прогнозирования позволяет точно определить перспективные запасы электроэнергии и открывает возможность оптимизации выработки с учетом изменения климата.

Результаты, полученные в ходе этого исследования, могут использоваться для повышения качества прогнозирования выработки электроэнергии изолированной системой ГБАО при принятии обоснованных решений относительно структуры выработки электроэнергии в регионе. Кроме того, предложенные методы могут быть рекомендованы для других электроснабжающих компаний, управляющих изолированными энергосистемами.

Направлением дальнейшей работы является создание адаптивной модели с возможностью периодического дообучения с появлением новых данных и замещением устаревшей части обучающей выборки. В этом случае модель будет постоянно и регулярно приспосабливаться к изменению условий работы.

СПИСОК ЛИТЕРАТУРЫ

1. Sachdev H.S., Akella A.K., Kumar N. Analysis and evaluation of small hydropower plants: A bibliographical survey // *Renewable and Sustainable Energy Reviews*. 2015. Vol. 51. Pp. 1013-1022. doi: 10.1016/j.rser.2015.06.065
2. A Comprehensive Study on the Recent Progress and Trends in Development of Small Hydropower Projects / T.S. Kishore, E.R. Patro, V.S. Harish, A.T. Haghighi // *Energies*. 2021. Vol. 14 (10). 2882. doi: 10.3390/en14102882
3. Algorithm for calculation and selection of micro hydropower plant taking into account hydrological parameters of small watercourses mountain rivers of Central Asia / M.S. Asanov, M.Kh. Safaraliev, T.Zh. Zhabudaev, S.M. Asanova, S.E. Kokin, S.A. Dmitriev, A.J. Obozova, A.H. Ghulomzoda // *International Journal of Hydrogen Energy*. 2021. Vol. 46. No. 75. Pp. 37109-37119. doi: 10.1016/j.ijhydene.2021.08.160
4. Bayazit Y., Bakış R., Koç C. A study on transformation of multi-purpose dams into pumped storage hydroelectric power plants by using GIS model // *International Journal of Green Energy*. 2020. Iss. 3. Pp. 1-11. doi: 10.1080/15435075.2020.1865362
5. Recloser-Based Decentralized Control of the Grid with Distributed Generation in the Lahsh District of the Rasht Grid in Tajikistan, Central Asia / A. Ghulomzoda, A. Gulakhmadov, A. Fishov, M. Safaraliev, X. Chen, K. Rasulzoda, K. Gulyamov, J. Ahyoev // *Energies*. 2020. Vol. 13. No. 14. 3673. doi: 10.3390/en13143673
6. Mayeda A.M., Boyd A.D. Factors influencing public perceptions of hydropower projects: A systematic literature review // *Renewable and Sustainable Energy Reviews*. 2020. Vol. 121. 109713. doi: 10.1016/j.rser.2020.109713
7. Baipenzhu Reservoir Inflow Flood Forecasting Based on a Distributed Hydrological Model / X. Shichao, Ch. Yangbo, X. Lixue, L. Chuan // *Water*. 2021. Vol. 13(3). 272. doi: 10.3390/w13030272
8. Banihabib M.E., Bandari R., Valipour M. Improving Daily Peak Flow Forecasts Using Hybrid Fourier-Series Autoregressive Integrated Moving Average and Recurrent Artificial Neural Network Models // *AI*. 2020. Vol. 1 (2). Pp. 263-275. doi: 10.3390/ai1020017
9. Albo-Salih H., Mays L. Testing of an Optimization-Simulation Model for Real-Time Flood Operation of River-Reservoir Systems // *Water*. 2021. Vol. 13. 1207. doi: 10.3390/w13091207
10. Priyanka S., Machiwal D. Streamflow forecasting: overview of advances in data-driven techniques // *Advances in Streamflow Forecasting*. 2021. No. 1. Pp. 1-50. doi: 10.1016/B978-0-12-820673-7.00013-5
11. Oluwaseun O., Stretch D. Neural network modeling of hydrological systems: A review of implementation techniques // *Natural Resource Modeling*. 2019. Vol. 32 (1). 12189. doi: 10.1111/nrm.12189
12. Capacity estimation of a minihydro plant based on time series forecasting / R. Peña, A. Medina, O. Anaya-Lara, J.R. McDonald // *Renewable Energy*. 2009. Vol. 34(5). Pp. 1204-1209. doi: 10.1016/j.renene.2008.10.011
13. Applying a Correlation Analysis Method to Long-Term Forecasting of Power Production at Small Hydropower Plants / G. Li, C.-X. Liu, S.-L. Liao, C.-T. Cheng // *Water*. 2015. Vol. 7 (9). Pp. 4806-4820. doi: 10.3390/w7094806
14. Future hydropower generation prediction of large-scale reservoirs in the upper Yangtze River basin under climate change / Z. Wenjie, G. Jing, Ch. Lu, Zh. Jianzhong, Zh. Junhong, W. Dangwei // *Journal of Hydrology*. 2020. Vol. 588. 125013. doi: 10.1016/j.jhydrol.2020.125013
15. Гуломзода А. Х., Сафаралиев М. Х., Люханов Е. А. Модифицированный способ синхронизации microgrid с внешней изолированной энергосистемой // *Электротехнические системы и комплексы*. 2021. № 3. С. 72-80. doi: 10.18503/2311-8318-2021-3(52)-72-80
16. Алгоритм выбора компенсирующих устройств на основе нечеткой логики / А.К. Киргизов, Ш.М. Султонов, С.Е. Кокин, М.Х. Сафаралиев // *Политехнический вестник. Серия: Инженерные исследования*. 2018. №4(44). С. 10-13.
17. Разработка моделей среднесрочного прогнозирования электропотребления в изолированно работающих энергосистемах на основе ансамблевых методов машинного обучения / С.М. Асанова, Дж.С. Ахеев, С.А. Дмитриев, П.В. Матренин, М.Х. Сафаралиев // *Известия НТЦ Единой энергетической системы*. 2021. № 1(84). С. 32-39.
18. Антоенков Д.В., Матренин П.В. Исследование ансамблевых и нейросетевых методов машинного обучения в задаче краткосрочного прогнозирования электропотребления горных предприятий // *Электротехнические системы и комплексы*. 2021. № 3(52). С. 57-65. doi: 10.18503/2311-8318-2021-3(52)-57-65
19. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. 785-794. doi: 10.1145/2939672.2939785
20. Официальный сайт Scikit-Learn. Machine learning in Python. URL: <https://scikit-learn.org> (дата обращения 01.02.2022)

Поступила в редакцию 19 декабря 2021 г.

INFORMATION IN ENGLISH

ADAPTIVE ENSEMBLE MODELS FOR MEDIUM-TERM FORECASTING OF POWER GENERATION BY HYDROPOWER PLANTS IN ISOLATED POWER SYSTEMS TAKING INTO ACCOUNT TEMPERATURE CHANGES

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, pavel.matrenin@gmail.com, <https://orcid.org/0000-0001-5704-0976>

Stepan A. Dmitriev

Ph.D. (Engineering), Associate Professor, Department of Automated Electrical Systems, Ural Federal University, Ural Power Engineering Institute, Yekaterinburg, Russia, dmstepan@gmail.com, <https://orcid.org/0000-0001-8781-2383>

Javod S. Ahoyev

Ph.D.(Engineering), Associate Professor, Department of Electric Stations, Tajik Technical University named after Academician M.S. Osimi, Dushanbe, Tajikistan, javod_66@mail.ru, <https://orcid.org/0000-0002-9869-288X>

Sergey E. Kokin

D.Sc. (Engineering), Professor, Department of Automated Electrical Systems, Ural Federal University, Ural Power Engineering Institute, Yekaterinburg, Russia, s.e.kokin@urfu.ru, <https://orcid.org/0000-0001-7493-172X>

The article analyzes the relationship between power generation at hydropower plants (HPPs) and temperature changes for medium-term forecasting in the isolated power system of the Gorno-Badakhshan Autonomous Oblast (GBAO) of the Republic of Tajikistan. Improving the accuracy of forecasting will solve the problem of controlling water consumption, as well as optimize the generation of electricity at the HPP with the provision of reliable functioning of the power system. The solution of such problems is associated with a number of problems such as the lack of sufficient data, the uncertainty of power generation, the lack of regularity of one station operation and poorly reliable forecasting models. In the medium-term forecasting of electricity generation at HPPs, the seasonality of changes in water flow and inflow should be taken into account, especially in power systems with a high proportion of renewable energy sources, where temperature changes directly affect reserves and the possibility of regulation. The paper considers the problem of constructing a model for medium-term forecasting of electricity generation at HPPs taking into account temperature changes in isolated power systems. As a method of medium-term forecasting of power generation, an approach based on machine learning methods was chosen, which is characterized by a high degree of self-adaptation in case of sudden changes in weather conditions. A comparative study of such models as linear/polynomial regression with Tikhonov regularization, k-nearest neighbours, adaptive boosting of decision trees, adaptive boosting of linear models, random forest, extreme gradient boosting, multilayer perceptron. As a result of experimental and industrial calculations, the expediency of using a model based on adaptive boosting with linear regression (ABLR) has been proved.

Keywords: ensemble models, medium-term forecasting, hydropower plant, power generation, isolated power system, temperature.

REFERENCES

1. Sachdev H.S., Akella A.K., Kumar N. Analysis and evaluation of small hydropower plants: A bibliographical survey. *Renewable and Sustainable Energy Reviews*, 2015, vol. 51, pp. 1013-1022. doi: 10.1016/j.rser.2015.06.065
2. Kishore T.S., Patro E.R., Harish V.S., Haghighi A.T. A Comprehensive Study on the Recent Progress and Trends in Development of Small Hydropower Projects. *Energies*, 2021, vol. 14(10), art. id. 2882. doi: 10.3390/en14102882
3. Asanov M.S., Safaraliev M.Kh., Zhabudaev T.Zh., Asanova S.M., Kokin S.E., Dmitriev S.A., Obozova A.J., Ghulomzoda A.H. Algorithm for calculation and selection of micro hydropower plant taking into account hydrological parameters of small watercourses mountain rivers of Central Asia. *Int. J. Hydrogen Energy*, 2021, vol. 46, no. 75, pp. 37109-37119. doi: 10.1016/j.ijhydene.2021.08.160
4. Bayazit Y., Bakış R., Koç C. A study on transformation of multi-purpose dams into pumped storage hydroelectric power plants by using GIS model. *International Journal of Green Energy*, 2020, pp. 1-11. doi: 10.1080/15435075.2020.1865362
5. Ghulomzoda A., Gulakhmadov A., Fishov A., Safaraliev M., Chen X., Rasulzoda K., Gulyamov K., Ahoyev J. Recloser-Based Decentralized Control of the Grid with Distributed Generation in the Lahsh District of the Rasht Grid in Tajikistan, Central Asia. *Energies*, 2020, vol. 13, no. 14, pp. 3673. doi: 10.3390/en13143673
6. Mayeda A.M., Boyd A.D. Factors influencing public perceptions of hydropower projects: A systematic literature review. *Renewable and Sustainable Energy Reviews*, 2020, vol. 121, art. id. 109713. doi: 10.1016/j.rser.2020.109713
7. Shichao X., Yangbo Ch., Lixue X., Chuan L. Baipenzhu Reservoir Inflow Flood Forecasting Based on a Distributed Hydrological Model. *Water*, 2021, vol. 13(3), art. id. 272. doi: 10.3390/w13030272
8. Banihabib M.E., Bandari R., Valipour M. Improving Daily Peak Flow Forecasts Using Hybrid Fourier-Series Autoregressive Integrated Moving Average and Recurrent Artificial Neural Network Models. *AI*, 2020, vol. 1(2), pp. 263-275. doi: 10.3390/ai1020017
9. Albo-Salih H., Mays L. Testing of an Optimization-Simulation Model for Real-Time Flood Operation of River-Reservoir Systems. *Water*, 2021, vol. 13, art. id. 1207. doi: 10.3390/w13091207
10. Priyanka S., Machiwal D. Streamflow forecasting: overview of advances in data-driven techniques. *Advances in Streamflow Forecasting*, 2021, pp. 1-50. doi: 10.1016/B978-0-12-820673-7.00013-5
11. Oluwaseun O., Stretch D. Neural network modeling of hydrological systems: A review of implementation techniques. *Natural Resource Modeling*, 2019, vol. 32(1), art. id. 12189. doi: 10.1111/nrm.12189
12. Peña R., et al. Capacity estimation of a minihydro plant based on time series forecasting. *Renewable Energy*, 2009, vol. 34(5), pp. 1204-1209. doi: 10.1016/j.renene.2008.10.011
13. Li G., Liu C.-X., Liao S.-L., Cheng C.-T. Applying a Correlation Analysis Method to Long-Term Forecasting of Power Production at Small Hydropower Plants. *Water*, 2015, vol. 7(9), pp. 4806-4820. doi: 10.3390/w7094806
14. Wenjie Z., Jing G., Lu Ch., Jianzhong Zh., Junhong Zh., Dangwei W. Future hydropower generation prediction of large-scale reservoirs in the upper Yangtze River basin under climate change. *Journal of Hydrology*, 2020, vol. 588, art. id. 125013. doi: 10.1016/j.jhydrol.2020.125013
15. Gulomzoda A.Kh., Safaraliev M.Kh., Lyukhanov E.A. A Modified method for synchronizing a microgrid with an external isolated power system. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical Systems and Complexes], 2021, no. 3, pp. 72-80. doi: 10.18503/2311-8318-2021-3(52)-72-80 (In Russian)
16. Kirgizov A.K., Sultonov Sh.M., Kokin S.E., Safaraliev M.Kh. Algorithm for selecting compensating devices based on fuzzy logic. *Politekhnikeskiiy vestnik. Seriya: Inzhenernye issledovaniya* [Polytechnic Bulletin. Series Engineering Research], 2018, no. 4 (44), pp.10-13. (In Russian)

17. Asanova S.M., Ahyoev J.S., Dmitriev S.A., Matrenin P.V., Safaraliev M.Kh. Development of models for power consumption medium-term forecasting in isolated power systems based on ensemble methods of machine learning. *Izvestiya NTTS Edinoy energeticheskoy sistemy* [Bulletin STC of the Unified Energy System], 2021, no. 1(84), pp. 32-39. (In Russian)
18. Antonenkov D.V., Matrenin P.V. Research of ensemble and neural network methods of machine learning in the problem of short-term forecasting of power consumption of mining enterprises. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical systems and complexes], 2021, no. 3(52), pp. 57-65. doi: 10.18503/2311-8318-2021-3(52)-57-65 (In Russian)
19. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. 2016, pp. 1-13. Available at: <https://arxiv.org/abs/1603.02754>. doi: 10.1145/2939672.2939785
20. Scikit-Learn. Machine learning in Python. Available at: <https://scikit-learn.org> (accessed 01 February 2022) (In Russian)

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, С.Е. Кокин // Электротехнические системы и комплексы. 2022. № 1(54). С. 38-45. [https://doi.org/10.18503/2311-8318-2022-1\(54\)-38-45](https://doi.org/10.18503/2311-8318-2022-1(54)-38-45)

Safaraliev M.Kh., Matrenin P.V., Dmitriev S.A., Ahyoev J.S., Kokin S.E. Adaptive Ensemble Models for Medium-Term Forecasting of Power Generation by Hydro-power Plants in Isolated Power Systems Taking into Account Temperature Changes. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical Systems and Complexes], 2022, no. 1(54), pp. 38-45. (In Russian). [https://doi.org/10.18503/2311-8318-2022-1\(54\)-38-45](https://doi.org/10.18503/2311-8318-2022-1(54)-38-45)