

МЕТОДЫ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ВЫРАБОТКИ ЭЛЕКТРИЧЕСКОЙ ЭНЕРГИИ СОЛНЕЧНЫМИ ЭЛЕКТРОСТАНЦИЯМИ И ИХ КЛАССИФИКАЦИЯ

В настоящее время мировое потребление энергии растет. Традиционные источники энергии становятся все более эффективными, но рост населения планеты ведет к общему увеличению энергопотребления. Так, по прогнозам Международного энергетического агентства, прогноз энергопотребления на 2030 год составит 33,4 трлн кВт·ч, а к 2050 году – до 41,3 трлн кВт·ч. В связи с этим для обеспечения роста глобальных запросов энергетике нужны принципиальные изменения, а именно децентрализация генерации, внедрение умных сетей (Smart Grid) и использование альтернативных источников энергии (энергии солнца и ветра). Лишь в этом случае удастся радикально снизить стоимость электроэнергии. Однако использование альтернативных источников энергии в рамках оптового рынка электроэнергии и мощности, действующего в настоящее время на территории Российской Федерации, невозможно без применения краткосрочных прогностических моделей «на сутки вперед». В данной статье проведен анализ существующих методов краткосрочного прогнозирования, которые применяются для построения прогнозов выработки электрической энергии на солнечных электростанциях, а также была проработана их классификация. На сегодняшний день существует уже довольно большое количество прогностических моделей, построенных в рамках каждого из выделенных методов краткосрочного прогнозирования, и все они отличаются своими особенностями. Поэтому для выделения наиболее перспективного для дальнейшего использования и развития метода краткосрочного прогнозирования был проведен анализ части из существующих прогностических моделей. В ходе исследования была оценена точность построения прогноза для каждого из методов краткосрочного прогнозирования и сделан вывод о перспективе использования и дальнейшего развития гибридного статистическо-адаптивного метода.

Ключевые слова: анализ данных, прогнозирование, электроэнергия, генерация, солнечные электростанции, возобновляемые источники энергии.

ВВЕДЕНИЕ

Одним из наиболее перспективных и активно развивающихся направлений возобновляемой энергетики является солнечная генерация электрической энергии. По всему миру темпы развития солнечных электростанций с 2016 года превышают темпы развития угольных электростанций [1].

На сегодняшний момент в мировой солнечной энергетике краткосрочное прогнозирование производства солнечной энергии не имеет проверенной и до конца испытанной технологии и зачастую связано с большими ошибками прогноза, достигающими иногда 60-65%. В то же время прогноз на более длительный период дает более точный результат, то же верно и для области – более точечный прогноз дает менее точный результат.

Фактически прогноз количества произведенной солнечной электростанцией электрической энергии является прогнозом количества полученной солнечными батареями солнечного излучения. На это влияет множество факторов, главные из которых метеорологические и климатические условия, в частности положение солнца на небе, продолжительность светового дня, осадки, облачность, сила ветра и т. д.

Все существующие на данный момент методы прогнозирования генерации электрической энергии солнечными электростанциями можно разделить на четыре основных группы, показанных на **рис. 1** [1]:

1. Физические модели описывают физические отношения между погодными условиями и солнеч-

ной радиацией, полученными с использованием численного прогноза погоды, и выработкой электрической энергии на станции.

2. Статистические модели описывают взаимосвязь между плотностью потока солнечного излучения, полученным с использованием численного прогноза погоды, и генерацией электрической энергии на солнечной электростанции путем статистического анализа временных рядов ретроспективных данных без учета физических факторов.

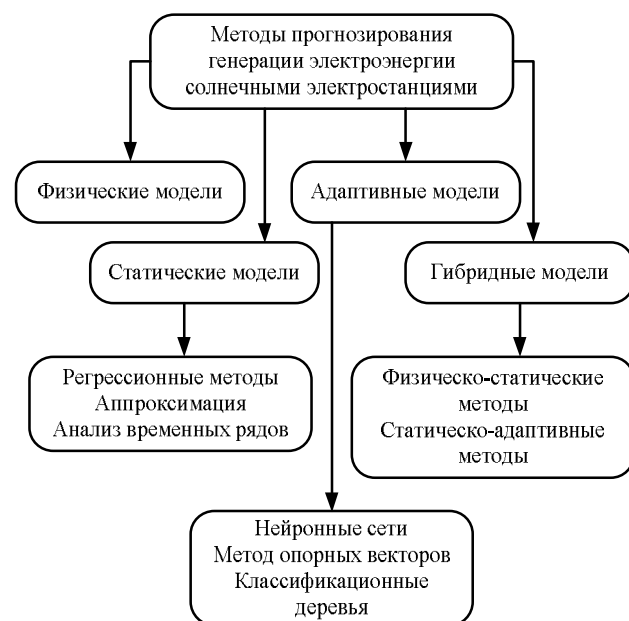


Рис. 1. Классификация методов прогнозирования генерации электроэнергии солнечной электростанции

3. Адаптивные модели используют системы искусственного интеллекта с целью определения связи между прогнозируемыми погодными условиями и выходной мощностью электростанции.

4. Гибридные модели в большинстве случаев представляют комбинацию физических и статистических моделей.

Численный прогноз погоды

Модели численного прогнозирования погоды в последние годы зачастую используются для выполнения краткосрочных прогнозов метеорологических переменных во многих различных применениях. Обычно эти модели классифицируют в соответствии с пространственно-временными характеристиками их прогнозов погоды. Каждая модель численного прогноза погоды прогнозирует атмосферные переменные со степенью качества, зависящей от географического расширения и временного разрешения их прогнозов [2]. Таким образом, модели с высоким пространственным масштабом получают прогнозы относительно более короткой временной достоверности, тогда как более длительные горизонты прогнозов достигаются с использованием моделей численного прогноза погоды меньшего пространственного масштаба [3].

Физические модели

В качестве входных переменных для физических моделей прогнозирования служат: численный прогноз погоды, местные метеорологические измерения, данные рельефа и тип земной поверхности, а также ретроспективные данные выходной мощности солнечной электростанции. Помимо этого, существует возможность использования спутниковых систем для отслеживания направления и скорости движения облаков, что предоставляет возможность прогнозирования солнечной радиации в режиме реального времени.

Практическое использование различных физических моделей в прогнозировании генерации электрической энергии показано в работах [4, 5].

В работе [4] рассматривается влияние значения аэрозольной оптической глубины на качество прогнозирования солнечного излучения с использованием моделей численного прогноза погоды MM5 [6] или Eta [7]. В результате работы показано, что при значении аэрозольной оптической глубины меньше 0,1 ошибка прогнозирования приемлема и составляет порядка 3-4%, а при значении аэрозольной оптической глубины больше 0,1 среднее отклонение составляет около 100 Вт/м².

В [5] представлена одна из физических моделей прогнозирования, основанная на кратковременных изменениях масштаба Октантов и изменениях температуры для определения среднечасовой выходной мощности фотоэлектрических систем на малых солнечных электростанциях, расположенных в городах Санандадж и Рашт. Данная модель имеет приемлемую точность при прогнозировании генерации солнечной энергии в облачную погоду, в то время как в солнечную она выдает в разы худшие результаты.

Статистические модели

В качестве входных данных для статистических моделей прогнозирования используются данные чис-

ленного прогноза погоды, в частности информация о солнечном излучении и ретроспективные данные генерации электрической энергии солнечной электростанцией. Статистические модели наиболее широко применяются для средне- и долгосрочного процессов прогнозирования [8].

Регрессионные методы

Одними из широко используемых статистических методов для прогнозирования электрической энергии являются регрессионные методы [9]. Они позволяют учитывать большое количество влияющих на прогноз факторов, в том числе метеорологических [10, 11].

При использовании регрессионных методов можно оценить причинно-следственные связи и зависимости в данных [12]. Кроме того, преимуществом данных методов является то, что они позволяют предсказать значение зависимой переменной по значениям независимых, но необходимо, чтобы значения признаков были некоррелированными.

Уравнение линейной регрессии имеет следующий вид:

$$Y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n + \varepsilon, \quad (1)$$

где Y – результирующий признак; $x_1 \dots x_n$ – факторные признаки; $b_1 \dots b_n$ – коэффициенты регрессии; a – свободный член уравнения; ε – «ошибка» модели.

Преимущество регрессионных методов состоит в простоте их реализации, а основным недостатком является непредсказуемость параметров, которые влияют на фактические значения. При возникновении резких изменений в имеющихся ретроспективных данных произойдет нарушение достоверности прогноза. Использование регрессионных методов хорошо применимо для поиска закономерностей в данных и для определения значимых факторов модели, но они не обеспечивают высокой точности при построении краткосрочных моделей прогнозирования генерации выработки электроэнергии.

Методы, основанные на временных рядах

Одним из наиболее часто используемых методов временных рядов является модель Бокса-Дженкинса – ARIMA (интегрированная модель авторегрессии – скользящего среднего) [13]. Данная модель применяется к нестационарным временным рядам, приводимым к стационарным, путем взятия разности некоторого порядка от исходных значений временного ряда.

Для нестационарного временного ряда X_t модель ARIMA имеет следующий вид:

$$\Delta^d X_t = c + \sum_{i=1}^p a_i \Delta^d X_{(t-i)} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t, \quad (2)$$

где ε_t – стационарный временной ряд; c , a_i , b_j – параметры модели; Δ^d – оператор разности временного ряда порядка d (последовательное взятие d раз разностей первого порядка – сначала от временного ряда, затем от полученных разностей первого порядка, затем от второго порядка и т.д.)

Также данная модель интерпретируется как AR-MA ($p + d, q$) – модель с d единичными корнями. При $d = 0$ имеем обычные ARMA-модели.

Методы, основанные на теории временных рядов, получили широкое распространение при построении краткосрочных прогнозов генерации электрической энергии, поскольку предприятия имеют большое количество ретроспективных данных о генерации электрической энергии солнечными электростанциями, а методы в данной группе нацелены на обработку больших массивов данных и позволяют находить в них закономерности, а также использовать эти закономерности при построении моделей прогноза. Основным недостатком данных методов является не обеспечение требуемой точности прогнозирования. Но при использовании методов временных рядов в комплексе, например с адаптивными моделями, требуемая точность достижима, но используемые в данном случае методы будут относиться к гибридным моделям.

В работах [14-19] показано практическое применение статистических моделей к прогнозированию выработки электрической энергии.

В [14] описывается двухэтапный метод прогнозирования электроэнергии солнечной электростанцией. На первом этапе производится статистическая нормализация солнечной энергии с использованием модели ясного неба, модель ясного неба была предложена в [20]. На втором этапе рассчитываются прогнозы нормированной солнечной энергии с использованием моделей временных рядов, в частности авторегрессионная модель и авторегрессионная модель с экзогенным входом, на который подается численный прогноз погоды. В результате работы показано, что использование авторегрессионной модели с экзогенным входом дает на 12% лучший результат, чем использование простой авторегрессионной модели при прогнозировании короткого горизонта и на 23% при прогнозировании следующего дня.

В работе [15] предложена модель прогнозирования солнечной энергии, учитывающая стохастичность облаков за счет применения различных параметров, учитывающих ослабление мощности. Основываясь на статистическом поведении параметров, был предложен простой процесс переключения между тремя классами: «солнечно», «облачно», «переменная облачность». Прогноз строится путем идентификации текущего режима и предположений о сохранении в этом режиме.

В работе [16] авторами предлагается очень краткосрочное прогнозирование солнечной энергии с применением классической концепции «сезонности», с выделением среднего значения или тренда и быстрых колебаний вокруг него. Особенностью данной работы является очень короткий временной горизонт в 1, 15 и 60 минут.

АДАПТИВНЫЕ МОДЕЛИ

Адаптивные модели имеют процесс «обучения», основанный на ретроспективном анализе данных. Данные модели в отличие от статистических могут неявно описывать сложные нелинейные взаимосвязи между погодными условиями и вырабатываемой солнечной электростанцией. Основным фактором, влияющим на точность прогноза, служит выборка и структура исходных данных, использованных для построения модели.

Методы с использованием нейронных сетей

Методы с использованием искусственных нейронных сетей в последнее время получили распространение не только при решении задач краткосрочного прогнозирования генерации солнечной энергии, но и средне- и долгосрочного прогнозирования. Искусственные нейронные сети состоят из множества нейронов входного, скрытых и выходного слоев, взаимодействующих друг с другом [21, 22]. Нейроны имеют функцию активации, зависящую от весовых коэффициентов связей между нейронами и смещения.

Для получения прогноза требуется проведение обучения нейронной сети. В процессе обучения подбираются значения смещений и весов для каждого нейрона так, чтобы выходной сигнал нейронной сети был как можно ближе к фактическому значению. Существует большое количество методов обучения нейронной сети [23], которые нашли применение и в прогнозировании генерации электроэнергии солнечными электростанциями.

Преимуществом нейронных сетей являются быстрые алгоритмы обучения и возможность работы при наличии шумовых входных сигналов. Соблюдение требований построения структуры нейронной сети с учетом избыточности нейронов, которое зависит от количества и выборки информативных признаков, сформированных для обучения искусственной нейронной сети, обеспечивает высокую надежность такой сети [24].

Метод опорных векторов

Метод опорных векторов является одной из популярных методологий обучения по прецедентам. Метод опорных векторов относится к семейству линейных классификаторов и применяется в задачах регрессионного анализа и классификации. Основная идея метода - перевод векторов в пространство большей размерности и поиск разделяющей гиперплоскости с максимальным зазором в ней [25]. От гиперплоскости, разделяющей классы по обеим сторонам, строятся две параллельные гиперплоскости. Гиперплоскость, у которой расстояние между двумя параллельными плоскостями максимально, и будет разделяющей.

Основными преимуществами метода опорных векторов являются способность получения правильного решения задачи при наличии неполных и искаженных данных и возможность учета большого количества дополнительных факторов, влияющих на качество прогнозирования [26]. Недостатком является необходимость обучения и повышенные требования к программно-аппаратным ресурсам.

Применение адаптивных моделей для прогнозирования генерации электроэнергии показано в работах [27-33].

В работе [27] демонстрируют применение деревьев решений для очень краткосрочного прогнозирования генерации электроэнергии солнечной электростанцией. В работе показано, что точность прогноза с использованием градиентного бустинга составила 75-65%. Прогноз строится на 1 час вперед.

В работе [28] рассматривается применение искусственной нейронной сети, адаптивной сети на основе системы нечеткого вывода и обобщенной нейронной

сети. Входными параметрами для предложенной модели служат: уровень солнечной радиации, температура окружающей среды, скорость ветра и температура модуля. В результате работы показано, что использование обобщенной нейронной сети дает наилучший результат.

В [29] авторы используют сеть радиально-базисных функций для прогнозирования солнечной энергии. В качестве входных данных используются данные об измерениях мощности и метеорологических прогнозах солнечного излучения, относительной влажности воздуха и температуры в месте расположения. Особенностью данной работы является предварительная классификация типа погоды (солнечно, облачно, дождливо) и применение для каждого класса различной структуры сети.

В работе [30] предлагается использование глубокой сети доверия для прогнозирования генерации солнечной энергии. В качестве входных параметров для сети используются данные об уровне солнечной радиации, температуры окружающей среды, относительной влажности и ретроспективные данные генерации солнечной энергии за пять дней до прогноза. В работе также было показано, что скорость ветра слабо влияет на генерацию солнечной энергии. В результате работы было показано, что модель, основанная на глубокой сети доверия, показывает лучший результат, чем модель, основанная на нейронной сети с обратным распространением ошибки.

ГИБРИДНЫЕ МОДЕЛИ

Гибридные методы объединяют в себе различные сочетания методов из других групп. Так, например, часто встречаются сочетания методов физических, статистических и адаптивных моделей.

Применение физических моделей не всегда оправдано из-за сложности точного учета определенных факторов, что требует введения статистического подхода для их определения. Статистические подходы имеют более высокую точность при расчете усредненных значений солнечного излучения за длительный период времени (день, месяц, год), в то время как за более короткий промежуток времени (минуты, часы), когда физические процессы, например облачность, не могут быть усреднены для данного интервала, они имеют гораздо меньшую точность. Для оптимальной точности гибридных моделей производится адаптация статистической модели к постоянно меняющимся условиям, которые описываются физическими моделями.

Большинство комбинированных подходов прогнозирования генерации солнечной энергии, как правило, могут использоваться либо для расчета ясных дней, либо облачных.

Еще одним примером гибридных моделей могут служить методы, сочетающие различные методы из статистических и адаптивных моделей. Такие гибридные методы имеют перспективы, поскольку позволяют учесть специфику физического процесса и использовать возможности адаптивных методов [34, 35]. Методы данной группы являются развивающимися, и экспертами находятся различные сочетания методов, обеспечивающих необходимую точность.

Применение гибридных моделей для прогнозирования генерации электроэнергии показано в работах [36, 37].

В работе [36] для прогнозирования генерации электроэнергии использовалась гибридная физико-статистическая модель. Два параметра, коэффициент прозрачности и коэффициент диффузии, определялись с использованием статистических моделей. Все остальные параметры определялись с использованием физических моделей. В результате применения метода ошибка составила 22,3%.

В [37] используется двухступенчатая модель, объединяющая работающие на первом этапе модель авторегрессионного интегрированного скользящего среднего, модель опорных векторов наименьших квадратов, искусственная нейронная сеть и адаптивная сеть на основе системы нечеткого вывода с генетическим алгоритмом на втором этапе. Ошибка метода в результате исследования составила порядка 5,21%.

ЗАКЛЮЧЕНИЕ

В работе была приведена основная классификация моделей прогнозирования генерации электрической энергии солнечными электростанциями на основе последних работ и публикаций. Кроме того, были рассмотрены различные способы применения методов прогнозирования. Средняя ошибка прогноза у представленных физических моделей составляет порядка 21–26%, статистических моделей – 20–24%, адаптивных – 15–19%, гибридных физико-статистических моделей – 19–24%, статистическо-адаптивных – 5–10%. На основе этого можно сделать вывод, что применение гибридных статистическо-адаптивных моделей дает наилучшие результаты прогнозирования и является наиболее перспективным направлением в области построения прогностических моделей генерации электрической энергии.

СПИСОК ЛИТЕРАТУРЫ

1. Ерошенко С.А., Халыямаа А.И., Снегирев Д.А. Подходы к прогнозированию плотности потока энергии солнечного излучения для СЭС // Энергоэксперт. 2017. № 5. С. 28–31.
2. Толстых М.А., Фролов А.В. Некоторые современные проблемы численного прогноза погоды // Известия РАН. ФАО. 2005. Т. 41. № 3. С. 315–327.
3. Грицай А.С. Гибридный метод краткосрочного прогнозирования потребления электрической энергии для энергосбытового предприятия с учетом метеофакторов. Омск, 2017. 153 с.
4. The Accuracy of Solar Irradiance Calculations Used in Mesoscale Numerical Weather Prediction / R.J. Zamora, E.G. Dutton, M. Trainer, S.A. McKeen, J.M. Wilczak, Y.T. Hou // Monthly Weather Review. 2005. Vol. 133. No. 4. P. 783–792.
5. Short-term solar power forecasting considering cloud coverage and ambient temperature variation effects / F.H. Gandoman, S.A. Aleem, N. Omar, A. Ahmadi, F.Q. Alenezi // Renewable Energy. 2018. Vol. 123. P. 793–805.
6. Akter N., Islam Md.N. Use of MM5 model for weather forecasting over Bangladesh region // BRAC University Journal. 2007. Vol. IV. P. 75–79.
7. Lazic L., Pejanovic G., Zivkovic M. Wind forecasts for wind power generation using the Eta model // Renewable Energy. 2009. Vol. 35. P. 1236–1243.
8. Кивчун О.Р. Метод векторного рангового анализа при управлении электропотреблением объектов военной инфраструктуры // Известия Тульского государственного университета. Технические науки. 2018. № 11. С. 550–560.

9. Тимчук С.А., Катюха И.А. Разработка критерия качества подбора коэффициентов регрессии в задачах прогнозирования электропотребления // Восточно-европейский журнал передовых технологий. 2014. Т. 5. № 8(71). С. 16–20.
10. Прогнозирование электропотребления с учетом температуры воздуха и естественной освещенности для региональных диспетчерских управлений / И.И. Надтока, А.В. Демур, С.О. Губский, А.Я. Ваколюк, В.В. Горбачев // Вестник Самарского государственного технического университета. Серия: технические науки. 2012. №1(33). С. 156–161.
11. Манусов В.З., Хохлова С.В. Сравнительный анализ двух моделей прогнозирования электрической нагрузки промышленных предприятий, построенных на основе регрессионного анализа и искусственных нейронных сетей // Научный вестник Новосибирского государственного технического университета. 2008. № 1 (30). С. 147–159.
12. Грицай А.С., Тюньков Д.А. Классификация методов краткосрочного прогнозирования электропотребления для субъектов ОРЭМ // Актуальные вопросы энергетики: материалы Всероссийской научной конференции студентов, магистрантов, аспирантов. Омск: ОмГТУ, 2016. С. 41–45.
13. Магнус Я.Р., Катышев П.К., Пересецкий А.А. Эконометрика. Начальный курс. М.: Дело, 2007. 504 с.
14. Bacher P., Madsen H., Nielsen H.A. Online short-term solar power forecasting // Solar Energy. 2009. Vol. 83. No. 10. P. 1772–1783.
15. Ramakrishna R., Scaglione A. A Compressive Sensing framework for the analysis of Solar Photo-Voltaic Power // Proceedings of 50th Asilomar Conference on Signals, Systems and Computers. Pacific Grove: IEEE, 2016. P. 308–3012.
16. Binding Statistical and Machine Learning Models for Short-Term Forecasting of Global Solar Radiation / L. Mora-López, I. Martínez-Marchena, M. Piliouge, M. Sidrach-de-Cardona // Lecture Notes in Computer Science. 2011. Vol. 7014. P. 294–305.
17. Модели краткосрочного прогнозирования выработки солнечных электростанций / Д.А. Снегирев, С.А. Ерошенко, А.И. Хальясмаа, В.В. Дубайлова // Электроэнергетика глазами молодежи – 2018: материалы IX Международной молодежной научно-технической конференции. Казань: КГЭУ, 2018. Т. 3. С. 179–182.
18. Кузнецов Н.П., Лысенко О.В. Статистический анализ энергетических показателей солнечной радиации (на примере данных Токмакской солнечной электростанции) // Проблемы региональной энергетики. 2017. №2(34). С. 139–147.
19. Кивчун О.Р. Метод векторного рангового анализа электропотребления объектов региональной инфраструктуры // Промышленная энергетика. 2018. №5. С. 36–43.
20. Chowdhury B.H., Rahman S. Forecasting sub-hourly solar irradiance for prediction of photovoltaic output // Proceedings of IEEE Photovoltaic Specialists Conference. New Orleans: IEEE, 1987. P. 171–176.
21. Манусов В.З., Бирюков Е.В. Краткосрочное прогнозирование электрической нагрузки на основе нечеткой нейронной сети и ее сравнение с другими методами // Известия Томского политехнического университета. 2006. Т. 309. № 6. С. 153–157.
22. Использование нейронной сети для построения краткосрочного прогноза электропотребления ООО «Омская энергосбытовая компания» / В.И. Потапов, А.С. Грицай, Д.А. Тюньков, Г.Э. Силин // Известия томского политехнического университета. Инжиниринг георесурсов. 2016. Т. 327. № 8. С. 44–51.
23. Хайкин С. Нейронные сети: пер. с англ. – М.: Вильямс, 2006. 1104 с.
24. Потапов В.И. Об эффективности обеспечения надежности избыточной нейронной системы со случайным периодом контроля и восстановления работоспособности после отказов нейронов // Омский научный вестник. 2010. №3(93). С. 202–203.
25. Вьюгин В.В. Математические основы теории машинного обучения и прогнозирования. М.: МЦМНО, 2013. 387 с.
26. Надтока И.И., Аль-Зихери Б.М. Краткосрочное прогнозирование нагрузки с помощью теории наименьших квадратов опорных векторов (LS-SVM) // Современные проблемы науки и образования. 2013. №6. Режим доступа: <https://www.science-education.ru/ru/article/view?id=11213>, свободный (дата обращения: 02.03.2019).
27. Eroschenko S., Khalyasmaa A., Snegirev D. Machine learning techniques for short-term solar power stations operational mode planning // E3S Web of Conferences. 2018. Vol. 51. doi: 10.1051/e3sconf/20185102004.
28. Generalized neural network methodology for short term solar power forecasting / V.P. Singh, V. Vijay, M.S. Bhatt, D.K. Chaturvedi // Proceedings of 13th International Conference on Environment and Electrical Engineering (EEEIC). – Wroclaw: IEEE, 2013. doi: 10.1109/eeeic-2.2013.6737883.
29. Online 24-h solar power forecasting based on weather type classification using artificial neural network / C. Chen, S. Duan, T. Cai, B. Liu // Solar Energy. 2011. Vol. 85. No. 11. P. 2856–2870.
30. Short-term output power forecasting of photovoltaic systems based on the deep belief net / L.L. Li, P. Cheng, H.C. Lin, H.Dong // Advances in Mechanical Engineering. 2017. Vol. 9. No. 9. doi: 10.1177/1687814017715983.
31. Степанов С.М., Искра Н.А. Нейросетевое прогнозирование генерации электроэнергии солнечными панелями // Доклады Белорусского государственного университета информатики и радиоэлектроники. 2018. №3(113). С. 26–31.
32. Воротынцев Д.В., Тягунов М.Г. Применение интеллектуальных информационных технологий в задаче прогнозирования солнечной энергии // Вестник Московского энергетического института. 2018. №4(4). С. 53–57.
33. Камшилова Ю.А. Прогноз выработки электроэнергии инвариантных ветроэнергетических установок методом нечеткой логики // Актуальные проблемы авиации и космонавтики. 2015. Т. 1. № 11. С. 316–318.
34. Гибридный метод краткосрочного прогнозирования электропотребления в условиях оптового рынка электроэнергии / А.С. Грицай, Д.А. Тюньков, Р.Н. Хамитов, Д.Д. Дугин, Г.Э. Силин // Электроэнергетика глазами молодежи: материалы VIII Международной научно-технической конференции. Самара: СамГТУ, 2017. Т. 3. С. 163–166.
35. О методе построения обучающей выборки в задачах краткосрочного прогнозирования электропотребления с учетом критериев информативности и компактности / Р.Н. Хамитов, А.С. Грицай, Д.А. Тюньков, Д.Д. Дугин, Г.Э. Силин // Промышленная энергетика. 2017. № 8. С. 23–28.
36. Особенности прогнозирования выработки электроэнергии солнечными электростанциями / Д.А. Снегирев, Р.Т. Валиев, С.А. Ерошенко, Ф.И. Хальясмаа // Электроэнергетика глазами молодежи: материалы VIII Международной научно-технической конференции. Самара: СамГТУ, 2017. Т. 3. С. 139–142.
37. Wu Y.K., Chen C.R., Rahman H.A. A Novel Hybrid Model for Short-Term Forecasting in PV Power Generation // International Journal of Photoenergy. 2014. Vol. 2014. doi: 10.1155/2014/569249.

Поступила в редакцию 04 июня 2020 г.

INFORMATION IN ENGLISH

SHORT-TERM FORECAST METHODS OF ELECTRICITY GENERATION BY SOLAR POWER PLANTS AND THEIR CLASSIFICATION

Dmitry A. Tyunkov

Post-graduate student, Teaching assistant, Department of Computer Science and Computer Engineering, Omsk State Technical University, Omsk, Russia. E-mail: dmitry.tyunkov@gmail.com. ORCID: 0000-0001-6496-7956

Alina A. Sapilova

Graduate student, Engineer, Department of Computer Science and Computer Engineering, Omsk State Technical University, Omsk, Russia. E-mail: alinka.s97@mail.ru

Aleksandr S. Gritsay

Ph.D. (Engineering), Associate Professor, Department of Computer Science and Computer Engineering, Omsk State Technical University, Omsk, Russia. E-mail: aleksandr.gritsay@gmail.com. ORCID: 0000-0003-0805-2086

Denis A. Alekseenko

Teaching assistant, Department of Computer Science and Computer Engineering, Omsk State Technical University, Omsk, Russia. E-mail: gnom1981@bk.ru

Rustam N. Khamitov

D.Sc. (Engineering), Professor, Department of Electrical Engineering, Omsk State Technical University, Omsk, Russia. E-mail: apple_27@list.ru. ORCID: 0000-0001-9876-5471

Currently, global energy consumption is growing. Traditional energy sources are becoming more efficient, but the growth of the world's population leads to a general increase in energy consumption. Thus, according to the forecasts of the International Energy Agency, the forecast for energy consumption for 2030 will be 33.4 trillion kW * h, and by 2050 it will increase to 41.3 trillion kW * h. In this regard, to ensure the growth of global demands, the energy sector needs fundamental changes, namely, decentralization of generation, introduction of smart grids (Smart Grid), and the use of alternative energy sources (solar energy and wind energy). Only in this case will it be possible to radically reduce the cost of electricity. However, the use of alternative energy sources within the framework of the wholesale electricity and capacity market currently operating on the territory of the Russian Federation is impossible without the use of such short-term day-ahead forecast models. This article analyzed the existing methods of short-term forecasting, which are used to build forecasts of the generation of electric energy in solar power plants. And also, their classification was worked out. To date, there is already a fairly large number of prognostic models built within the framework of each of the selected methods for short-term forecasting, and all of them differ in their features. Therefore, to highlight the most promising method for short-term forecasting for further use and development, an analysis of some of the existing prognostic models was carried out. During the study, the accuracy of forecasting for each of the short-term forecasting methods was evaluated and a conclusion was drawn on the prospects for the use and further development of a hybrid statistical-adaptive method.

Keywords: data mining, forecast, electricity, generation, solar power plants, renewable energy sources.

REFERENCES

1. Eroshenko S.A., Khalyasmaa A.I., Snegirev D.A. Approaches to prediction of the flux density of solar energy for SPS. *Energoekspert* [Energy expert], 2017, no. 5, pp. 28–31. (In Russian)
2. Tolstykh M.A., Frolov A.V. Some current problems in numerical weather prediction. *Izvestiya RAN*. [Proceedings of the Russian Academy of Sciences], 2005, vol. 41, no. 3, pp. 285–295. (In Russian)
3. Gritsay A.S. *Gibridnyy metod kratkosrochnogo prognozirovaniya potrebleniya elektricheskoy energii dlya energosbytovogo predpriyatiya s uchetom meteo faktorov* [Hybrid method of short-term forecasting of electric energy consumption for a power sales company taking into account meteorological factors]. Omsk, 2017. 153 p. (In Russian)
4. Zamora R.J., Dutton E.G., Trainer M., McKeen S.A., Wilczak J.M., Hou Y.T. The Accuracy of Solar Irradiance Calculations Used in Mesoscale Numerical Weather Prediction. *Monthly Weather Review*, 2005, vol. 133, no. 4, pp. 783–792.
5. Gandoman F.H., Aleem S.A., Omar N., Ahmadi A., Alesnezi F.Q. Short-term solar power forecasting considering cloud coverage and ambient temperature variation effects. *Renewable Energy*, 2018, vol. 123, pp. 793–805.
6. Akter N., Islam Md.N. Use of MM5 model for weather forecasting over Bangladesh region. *BRAC University Journal*, 2007, vol. IV, pp. 75–79.
7. Lazic L., Pejanovic G., Zivkovic M. Wind forecasts for wind power generation using the Eta model. *Renewable Energy*, 2009, vol. 35, pp. 1236–1243.
8. Kivchun O.R. The vector rank analysis in energy management of military infrastructure objects. *Izvestiya Tula gosudarstvennogo universiteta. Tekhnicheskie nauki* [Proceedings of Tula State University. Technical sciences]. 2018, no. 11, pp. 550–560. (In Russian)
9. Timchuk S.A., Katyuha I.A. Development of regression coefficient selection quality criterion in power consumption forecasting problems. *Vostochno-evropeyskiy zhurnal peredovykh tekhnologiy* [Eastern-European Journal of Enterprise Technologies], 2014, vol. 5, no. 8 (71), pp. 16–20. (In Russian)
10. Nadtocha I.I., Demura A.V., Gubskiy S.O., Vakolyuk A.J., Gorbachev V.V. Energy consumption prediction model for temperature and lighting of regional dispatch administrations. *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: tekhnicheskie nauki* [Bulletin of Samara State Technical University. Technical Sciences Series], 2012, vol. 1 (33), pp. 156–161. (In Russian)
11. Manusov V.Z., Khokhlova S.V. Comparative analysis of two models of electrical load prediction of industrial enterprises based on regression analysis and artificial neural networks. *Nauchnyy vestnik Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta* [Science bulletin of Novosibirsk State Technical University], 2008, vol. 1 (30), pp. 147–159. (In Russian)
12. Gritsay A.S., Tyunkov D.A. Classification of methods for short-term power consumption forecasting for WECM sub-

- jects. *Aktualnye voprosy energetiki. Materialy Vserossiyskoy nauchnoy konferentsii studentov, magistrantov, aspirantov* [Actual energy issues: Proc. of the All-Russian scientific conference of students, undergraduates, PhD student]. Omsk, OmGTU Publ., 2016, pp. 41–45. (In Russian)
13. Magnus Ya.R., Katyshev P.K., Peresetskiy A.A. *Ekonometrika. Nachal'nyy kurs* [Econometrics. Initial course]. Moscow, Delo Publ., 2007. 504 p.
14. Bacher P., Madsen H., Nielsen Y.A. Online short-term solar power forecasting. *Solar Energy*, 2009, vol. 83, no. 10, pp. 1772–1783.
15. Ramakrishna R. Scaglione A. A Compressive Sensing framework for the analysis of Solar Photo-Voltaic Power. *Proceedings of 50th Asilomar Conference on Signals, Systems and Computers*. Pacific Grove, IEEE Publ, 2016, pp. 308–3012.
16. Mora-López L., Martínez-Marchena I., Piliouge M., Sidrach-de-Cardona M. Binding Statistical and Machine Learning Models for Short-Term Forecasting of Global Solar Radiation. *Lecture Notes in Computer Science*, 2011, vol. 7014, pp. 294–305.
17. Snegirev D.A., Eroshenko S.A., Halyasmaa A.I., Dubaylova V.V. Short-term photovoltaic power plants generation forecasting model. *Elektroenergetika glazami molodezhi – 2018: Materialy IX Mezhdunarodnoy molodezhnoy nauchno-tekhnicheskoy konferentsii* [Electric power industry through the eyes of youth – 2018: Proc. of the IX International Youth Scientific and Technical Conference]. Kazan, KGEU Publ, 2018, vol. 3, pp. 179–182. (In Russian)
18. Kuznetsov N.P., Lysenko O.V. Statistical analysis of energy indices of solar radiation (Based on the data of Tokmak Solar Power Station). *Problemy regionalnoy energetiki* [Problems of the regional power industry], 2017, no. 2 (34), pp. 139–147. (In Russian)
19. Kivchun O.R. The method of vector rank analysis of power consumption of regional infrastructure objects. *Promyshlennaya energetika* [Industrial power engineering], 2018, no. 5, pp. 36–43. (In Russian)
20. Chowdhury B.H., Rahman S. Forecasting sub-hourly solar irradiance for prediction of photovoltaic output *Proceedings of IEEE Photovoltaic Specialists Conference*. New Orleans, IEEE Publ, 1987, pp. 171–176.
21. Manusov V.Z., Biruikov E.V. Short-term load prediction on the basis of fuzzy neural network and its comparison with other methods. *Izvestiya Tomskogo politekhnicheskogo universiteta* [Bulletin of Tomsk Polytechnic University], 2006, vol. 309, no. 6, pp. 153–157. (In Russian)
22. Potapov V.I., Gritsay A.S., Tyunkov D.A., Sinitsin G.E. Using neural network for building short) term forecast of electricity load of LLC "Omsk energy retail company". *Izvestiya Tomskogo politekhnicheskogo universiteta* [Bulletin of Tomsk Polytechnic University], Geo Assets Engineering, 2016, vol. 327, no. 8, pp. 44–51. (In Russian)
23. Haykin S. *Neyronnye seti: per. s angl.* [Neural networks: translated from English]. Moscow, Williams Publ., 2006, 1104 p. (In Russian)
24. Potapov V.I. On the effectiveness of providing reliability of redundant neural systems with a random period of monitoring and recovery of operability after the neurons failure. *Omskiy nauchnyy vestnik* [Omsk Scientific Bulletin], 2010, no. 3 (93), pp. 202–203. (In Russian)
25. Vyugin V.V. *Matematicheskie osnovy teorii mashinnogo obucheniya i prognozirovaniya* [Mathematical foundations of the theory of machine learning and forecasting]. Moscow, MCMNO Publ., 2013, 387 p. (In Russian)
26. Nadtoka I.I., Al-Zihery B.M. Short term load forecasting by using least squares support vector machine theory. *Scientific journal Modern problems of science and education*, 2013, no. 6. Available at: <https://www.science-education.ru/ru/article/view?id=11213> (accessed 02 March 2019). (In Russian)
27. Eroshenko S., Khalyasmaa A., Snegirev D. Machine learning techniques for short-term solar power stations operational mode planning. *E3S Web of Conferences*, 2018, vol. 51, doi: 10.1051/e3sconf/20185102004.
28. Singh V.P., Vijay V., Bhatt M.S., Chaturvedi D.K. Generalized neural network methodology for short term solar power forecasting. *Proceedings of 13th International Conference on Environment and Electrical Engineering (EEEIC)*. Wroclaw, IEEE Publ., 2013, doi: 10.1109/eeeic-2.2013.6737883.
29. Chen C., Duan S., Cai T., Liu B. Online 24-h solar power forecasting based on weather type classification using artificial neural network. *Solar Energy*, 2011, vol. 85, no. 11, pp. 2856–2870.
30. Li L.L., Cheng P., Lin H.C., Dong H. Short-term output power forecasting of photovoltaic systems based on the deep belief net. *Advances in Mechanical Engineering*, 2017, vol. 9, no. 9, doi: 10.1177/1687814017715983.
31. Stepanov S.M., Iskra N.A. Neural network forecasting of energy generation by solar panels. *Doklady Belorusskogo gosudarstvennogo universiteta informatiki i radioelektroniki* [Proceedings of the Belarusian State University of Informatics and Radioelectronics], 2018, no. 3 (113), pp. 26–31. (In Russian)
32. Vorotyntsev D.V., Tyagunov M.G. Forecasting the Power Output Produced by Photovoltaic Power Plants (for the day ahead) Using Machine Learning Techniques. *Vestnik Moskovskogo energeticheskogo instituta* [Bulletin of Moscow Power Engineering Institute], 2018, no. 4(4), pp. 53–57. (In Russian)
33. Kryukov O.V., Serebryakov A.V. Forecast of Power Generation Invariant Wind Power Installation by Method of Fuzzy Logic. *Aktualnye problemy aviatsii i kosmonavтики* [Topical Issues of Air Transport and Space Technology], 2015, vol. 1, no. 11, pp. 316–318. (In Russian)
34. Gritsay A.S., Tyunkov D.A., Khamitov R.N., Dugin D.D., Sinitsin G.E. Forecast of electricity load via hybrid method on the wholesale power market. *Elektroenergetika glazami molodezhi: Materialy VIII Mezhdunarodnoy molodezhnoy nauchno-tekhnicheskoy konferentsii* [Electric power industry through the eyes of the youth: Proc. of the VIII International Scientific and Technical Conference]. Samara: SamGTU, 2017, vol. 3, pp. 163–166. (In Russian)
35. Khamitov R.N., Gritsay A.S., Tyunkov D.A., Dugin D.D., Sinitsin G.E. On the method of constructing a learning sample in the problems of short-term forecasting of power consumption with allowance for the criteria of information value and compactness. *Promyshlennaya energetika* [Industrial power engineering], 2017, no. 8, pp. 23–28. (In Russian)
36. Snegirev D.A., Valiev R.T., Eroshenko S.A., Khalyasmaa A.I. Specific features of photovoltaic power plants generation forecasting. *Elektroenergetika glazami molodezhi: Materialy VIII Mezhdunarodnoy molodezhnoy nauchno-tekhnicheskoy konferentsii* [Electric power industry through the eyes of the youth: Proc. of the VIII International Scientific and Technical Conference]. Samara: SamGTU, 2017, vol. 3, pp. 139–142. (In Russian)
37. Wu Y.K., Chen C.R., Rahman H.A. A Novel Hybrid Model for Short-Term Forecasting in PV Power Generation. *International Journal of Photoenergy*, 2014, vol. 2014, doi: 10.1155/2014/569249.

Методы краткосрочного прогнозирования выработки электрической энергии солнечными электростанциями и их классификация / Тюнков Д.А., Сапилова А.А., Грицай А.С., Алексеенко Д.А., Хамитов Р.Н. // *Электротехнические системы и комплексы*. 2020. № 3(48). С. 4–10. [https://doi.org/10.18503/2311-8318-2020-3\(48\)-4-10](https://doi.org/10.18503/2311-8318-2020-3(48)-4-10)

Tyunkov D.A., Sapilova A.A., Gritsay A.S., Alekseenko D.A., Khamitov R.N. Short-Term Forecast Methods of Electricity Generation by Solar Power Plants and their Classification. *Elektrotekhnicheskie sistemy i komplekсы* [Electrotechnical Systems and Complexes], 2020, no. 3(48), pp. 4–10. (In Russian). [https://doi.org/10.18503/2311-8318-2020-3\(48\)-4-10](https://doi.org/10.18503/2311-8318-2020-3(48)-4-10)