

УДК 303.724.32

DOI: 10.35211/1990-5297-2023-1-272-66-68

*Д. С. Князев, Е. Г. Шведов, И. В. Волков***РАЗРАБОТКА ПРОГНОЗИРУЮЩЕЙ МОДЕЛИ ВЫРАБОТКИ
СУТОЧНОЙ ЭНЕРГИИ ВЕТРОГЕНЕРАТОРОМ****Волгоградский государственный технический университет**

E-mail: dimagold.dg53@gmail.com

Рассматривается регрессионная модель, прогнозирующая посуточную выработку энергии ветрогенератором. Описывается методика создания данной модели на основе машинного обучения. Оценивается ее точность прогнозирования.

Ключевые слова: модель, линейная регрессия, ветрогенератор, признак, выборка, коэффициент, аппроксимация, энергия, индикатор.

*D. S. Knyazev, E. G. Shvedov, I. V. Volkov***DEVELOPMENT OF A PREDICTIVE MODEL
OF DAILY ENERGY GENERATION BY A WIND GENERATOR****Volgograd State Technical University**

A regression model predicting the daily energy output of a wind generator is considered. The method of creating this model based on machine learning is described. Its prediction accuracy is evaluated.

Keywords: model, linear regression, wind generator, feature, sampling, coefficient, approximation, energy, indicator.

Ветрогенераторы являются неотъемлемым элементом, входящим в состав автономных комбинированных комплексов выработки альтернативной энергии. Средние показатели выработки энергии имеют сезонную зависимость с учетом розы ветров и конкретного региона. Для регионов, где преобладает технический ветер, ветрогенераторы, в отличие от солнечных батарей, сохраняют свою эффективность в зимний период. Основная проблема ветровых станций заключается в том, что их эффективность мала при низких скоростях ветра или его нестабильности (малое накопление энергии и сильные колебания мощностей). В этом случае, автоматические системы управления энергией не всегда способны правильно регулировать внутренние энергопотоки. При таком процессе сложно оценить количество энергии, которое будет запасено в накопительные элементы с помощью ветровой станции. На боль-

шей части территории России средняя скорость ветра составляет 4-5 м/с, что является недостаточным фактором для стабильной выработки энергии. Однако, в случае крайней необходимости использования ветрогенератора в качестве основного поставщика энергии (ввиду отсутствия возможности организации других видов энергообеспечения объекта) необходимо спрогнозировать теоретический энергетический потенциал данной системы методом прогнозирования на основе исторических данных. Это позволит наиболее эффективно накапливать и распределять энергию, а также формировать прогнозы времени работы потребителей.

В связи с вышеизложенной задачей разработана математическая модель прогнозирования суточной выработки энергии ветрогенератором на основе регрессионного анализа и машинного обучения. Объектом исследования




Рис. 1. Данные о суточных мощностях, выработанные одним ветрогенератором

являлись данные скорости ветра и вырабатываемой мгновенной мощности, которые фиксировались на ветрогенераторах Ульяновской ВЭС за 2021 гг. (рис. 1).

Признаками для обучения модели являлись данные о суточной выработке энергии. По этим данным рассчитывались 17 технических инди-

каторов, описывающие колебания. Также в качестве признаков были взяты значения характеристик выработки энергии соседних ветрогенераторов. По их данным тоже рассчитывались технические индикаторы. В итоге получаем таблицу данных, состоящую из 64 колонок (рис. 2).

	TimeStart	ShortMA	MedMA	LongMA	AngShortMA	AngMedMA	AngLongMA	X2Long_delta	kX2	ATR	...	HighP	LowP	NightP	V k!
0	1.609448e+09	0.0000	0.0000	0.0000	0.00	0.00	0.00	1.3390	1.0514	0.0000	...	1.344	1.339	1.339	6172.0
1	1.609449e+09	0.0000	0.0000	0.0000	0.00	0.00	0.00	1.3400	0.0000	0.0000	...	1.342	1.339	1.340	2129.0
2	1.609449e+09	0.0000	0.0000	0.0000	0.00	0.00	0.00	1.3370	0.0000	0.0000	...	1.340	1.333	1.337	13630.0
3	1.609449e+09	0.0000	0.0000	0.0000	0.00	0.00	0.00	1.3320	0.0000	0.0000	...	1.337	1.332	1.332	4937.0
4	1.609449e+09	0.0000	0.0000	0.0000	-0.00	-0.00	-0.00	1.3300	0.0000	0.0000	...	1.336	1.329	1.330	16979.0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
50157	1.618476e+09	1.2039	1.1890	1.1449	-0.38	0.96	0.34	0.0541	0.8663	0.0220	...	1.203	1.180	1.199	193507.0
50158	1.618476e+09	1.2021	1.1893	1.1455	-0.16	0.79	0.32	0.0445	0.6034	0.0223	...	1.207	1.181	1.190	312901.0
50159	1.618477e+09	1.1979	1.1903	1.1458	-0.43	0.66	0.29	0.0392	0.4909	0.0212	...	1.190	1.183	1.185	19197.0
50160	1.618477e+09	1.1946	1.1915	1.1463	-1.11	0.58	0.26	0.0427	0.5997	0.0207	...	1.189	1.174	1.189	118887.0
50161	1.618477e+09	1.1909	1.1923	1.1467	-1.62	0.52	0.22	0.0373	0.4782	0.0215	...	1.199	1.168	1.184	178999.0

Рис. 2. Данные технических индикаторов

Для обучения регрессионной модели данные делятся на матрицу признаков и целевую функцию – вектор-столбец, который модель прогнозирует. В качестве целевой функции была взята мощность, вырабатываемая на ветрогенераторе за первую половину дня. Чтобы модель прогнозировала мощность на следующий

день, вектор-столбец со значениями о выработанной мощности ветрогенератором был смещен на один элемент вверх. Далее данные делятся на обучающую и тестовую выборки (рис. 3). Для выборок задаем четыре переменные: для обучающей – X_{train} , y_{train} , для тестовой – X_{test} , y_{test} .




Рис. 3. Разбиение данных на обучающую и тестовую выборки

Уравнение линейной регрессии в общем виде выглядит так:

$$z = a_0 + \sum_{i=1}^{63} a_i x_i, \quad (1)$$

где a_0 – параметр, a_i – коэффициент перед соответствующим признаком x_i .

Для аппроксимации коэффициентов линейной регрессии a_i используется градиентный спуск – алгоритм численной оптимизации, который выбирает случайную точку, рассчитывает направление скорейшего убывания функции,

а затем пошагово рассчитывает новые значения функции, двигаясь в выбранную сторону. Алгоритм позволяет найти глобальный минимум функции потерь (2):

$$\sum_{i=0}^N (y_i - z_i)^2, \quad (2)$$

где y_i – наблюдаемые значения, z_i – спрогнозированные значения, N – число наблюдений.

Итоговые значения коэффициентов после оптимизации показаны в таблице (рис. 4).

	coef
LongMA	1.014301
X2Long_delta	0.233149
HighP	0.007931
LowP	0.006364
ShortMAE	0.001296
...	...
X2Long_deltaE	-0.000558
MedMAB	-0.000875
LongMAE	-0.001954
ShortMA	-0.003049
NightP	-0.759220

Рис. 4. Значения коэффициентов модели

Результаты обучения модели (1) также показаны на графике (рис. 5).




Рис. 5. Результат обучения модели (1)

В качестве оценки точности была выбрана средняя абсолютная ошибка на тестовой выборке. Формула величины средней абсолютной ошибки имеет вид:

$$MAE = \frac{1}{n} \sum_{i=0}^{n-1} |y_n - z_n|. \quad (3)$$

Также необходимо посчитать относительную погрешность для оценки модели. Ее формула будет иметь вид:

$$\vartheta = \frac{\sigma_u}{\bar{y}} \cdot 100\%. \quad (4)$$

Результаты моделирования:

Средняя абсолютная ошибка на тестовой выборке: 0,001.

Относительная погрешность на тестовой выборке: 0,113 %.

В результате исследования была получена регрессионная математическая модель для про-

гнозирования выработанной энергии ветрогенератором за 24 часа. Данная модель позволяет произвести прогнозируемую оценку выработки энергии ветрогенератором на день вперед и обеспечить повышение эффективности использования ветрогенераторов в составе устройств безуглеродной энергетики России.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Расчет выработки энергии вырабатываемой ветровой станцией: сайт. - 2022. - URL: <https://energotrade.su/windenergy/raschet.htm> (дата обращения: 01.09.22)
2. Николенко, С. Глубокое обучение / С. Николенко, А. Кадури, Е. Архангельская. – СПб. : Питер, 2018. – 480 с.
3. Жерон, Орельен. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем / Жерон, Орельен ; пер. с англ. – СПб. : ООО «Альфа-книга», 2018. – 688 с.