

# Analiza ważności danych wejściowych dla krótkoterminowej prognozy generacji PV w zakładzie przemysłowym

**Streszczenie.** Artykuł przedstawia analizę statystyczną danych stanowiących potencjalne zmienne wejściowe do modeli prognostycznych w zadaniu prognozowania generacji energii z horyzontem 15 minut przez elektrownię słoneczną działającą na potrzeby zakładu przemysłowego. Dokonano wyboru tych zmiennych a następnie oceniono ich ważność dla wybranych modeli uczenia maszynowego. Do prognoz wykorzystano m.in.: sieć neuronową typu MLP, las losowy, drzewa decyzyjne wzmocnione gradientowo oraz regresję liniową wieloraką. Zakończenie artykułu stanowią wnioski z wykonanych badań.

**Abstract.** The article presents a statistical analysis of data that constitute potential input variables for forecasting models in the task of predicting energy generation with a 15-minute horizon by a solar power plant operating for the needs of an industrial facility. A selection of these variables was made, followed by an evaluation of their importance for selected machine learning models. The forecasts used include: a Multilayer Perceptron neural network, random forest, gradient boosting decision trees and multiple linear regression. The article concludes with the findings from the conducted research. (**Input data importance for short-term forecasting of a PV generation in an industrial facility**).

**Słowa kluczowe:** uczenie maszynowe, ważność cech, elektrownia słoneczna, krótkoterminowa prognoza

**Keywords:** machine learning, feature importance, solar power plant, short-term forecasting

## Wstęp

Transformacja energetyczna obiektów przemysłowych jest zagadnieniem wieloaspektowym. Redukcja śladu węglowego może zostać osiągnięta za pomocą poprawy efektywności energetycznej, ograniczanie zapotrzebowania przez częściowe zasilanie obiektu ze źródeł odnawialnych, ustalanie reżimów pracy urządzeń zakładu przemysłowego tak oraz zarządzanie odpadami przemysłowymi [1,2]. Im bardziej energochłonny zakład przemysłowy, tym większy potencjał redukcji śladu węglowego – jako przykład można tu podać przemysł związany z żelazem i stalą [2].

W pracach poświęconych efektywności energetycznej można znaleźć informacje dotyczące zarówno wytycznych dla decydentów [3,4], oceny skuteczności istniejących polityk [5,6], jak i wdrożenia wybranych metod ograniczania CO<sub>2</sub> [7,8], czy też maksymalizacji produkcji z OZE [9].

Niniejsze badania stanowią fragment międzynarodowego Projektu Diego, mającego zapewnić skalowalne i powtarzalne rozwiązania służące redukcji śladu węglowego obiektów przemysłowych. Celem projektu jest wypracowanie zarówno technicznych środków poprawy efektywności energetycznej oraz opracowanie wytycznych zapewniających transfer rozwiązań między różnymi obiektami przemysłowymi. Prace te wpisują się również w ogólny charakter tła literaturowego.

Badania wykonane w ramach projektu związane są z prognozowaniem energii wytwarzanej przez instalację PV, w którą wyposażony jest analizowany zakład przemysłowy. Prognozy te, będą w dalszej kolejności stosowane do wysterowania pracy zakładu przemysłowego w sposób umożliwiający redukcję jego śladu węglowego. W założeniu, redukcja ta ma zostać zapewniona przez wykonywanie optymalizacji nadążnej pracy zakładu z rozdzielczością 15 minut. Ze względu na konieczność automatyzacji procesu istotne staje się poznanie potencjalnej wrażliwości modeli prognostycznych na zaburzenia mogące wystąpić w dostępnych w danym momencie danych wykorzystywanych przez model prognostyczny. W przypadku wykrycia awarii w sygnałach pomiarowych możliwe staje się przełączenie wykorzystywanego modelu na wcześniej utworzony model awaryjny, który przypisuje mniejszą wagę do określonych zmiennych. Z drugiej strony analiza taka

umożliwia typowanie składowych do budowy wiązek modeli prognostycznych.

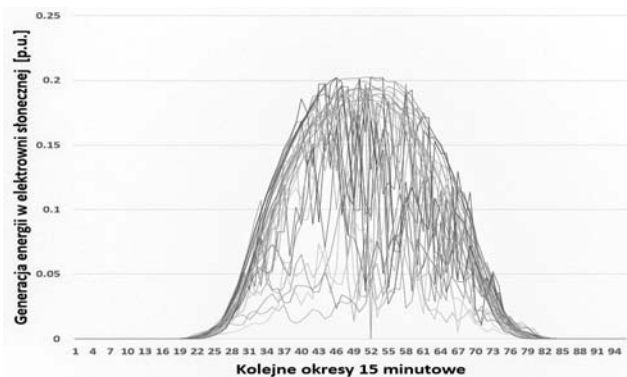
Ze względu na horyzont prognoz wynoszący 15 minut, przedstawione badania można traktować jako prognozy krótkoterminowe lub ultrakrótkoterminowe [10,11]. Szerszą typologię prac związanych z generacją z OZE można znaleźć m.in. w [12].

## Analiza statystyczna danych

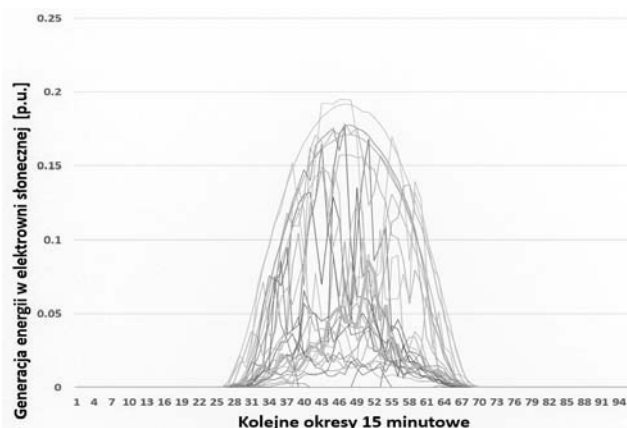
Elementem poprzedzającym właściwe badania był pre-processing dostępnych szeregów czasowych, czyli generacji energii elektrycznej przez elektrownię słoneczną oraz historycznych danych meteorologicznych (wartości 1 minutowe). Dane zostały najpierw „oczyszczone” w celu rozwiązania problemów zmiany czasu i brakujących oraz niewiarygodnych danych, a następnie przekonwertowane do wartości 15-minutowych. Ponadto w celu anonimizacji, dane zostały znormalizowane do jednostek względnych. Dla szeregów czasowych generacji piętnastominutowej z paneli fotowoltaicznych, jedna jednostka względna (p.u.) była równa mocy znamionowej PV. Dla pozostałych zmiennych zastosowano normalizację metodą min-max.

Tabela 1. Wybrane statystyki opisowe dla szeregu czasowego generacji energii z elektrowni słonecznej oraz nasłonecznienia

Statystyka	Generacja energii	Nasłonecznienie
Średnia arytmetyczna	0,0584 [p.u.]	258,968 [W/m <sup>2</sup> ]
Odchylenie standardowe	0,0627 [p.u.]	284,144 [W/m <sup>2</sup> ]
Minimum	0 [p.u.]	0 [W/m <sup>2</sup> ]
Maksimum	0,203 [p.u.]	1000 [W/m <sup>2</sup> ]
Rozstęp	0,203 [p.u.]	1000 [W/m <sup>2</sup> ]
Współczynnik zmienności	107,362 [%]	109,721 [%]
Percentyl 10	0 [p.u.]	0 [W/m <sup>2</sup> ]
Percentyl 25 (dolny kwartyl)	0,00414 [p.u.]	25,142 [W/m <sup>2</sup> ]
Percentyl 50 (mediana)	0,03159 [p.u.]	131,333 [W/m <sup>2</sup> ]
Percentyl 75 (górnny kwartyl)	0,10443 [p.u.]	447 [W/m <sup>2</sup> ]
Percentyl 90	0,16449 [p.u.]	732,857 [W/m <sup>2</sup> ]
Wariancja	0,003936	80737,818
Skosność	0,8655	0,9828
Kurtოza	-0,6024	-0,28475



Rys.1 Zmienność dobową generacji energii elektrycznej w miesiącu sierpnie 2022 (31 dni).



Rys.2 Zmienność dobową generacji energii elektrycznej w miesiącu lutym 2022 (28 dni).

Do celów analizy statystycznej wykorzystano kompletne dane z każdej doby (kolejno następujące 96 wartości z granulacją 15 min). Całościowo do badań zebrano dane z jednego roku kalendarzowego. W Tabeli 1 przedstawiono wybrane statystyki opisowe dla szeregu czasowego generacji energii z paneli fotowoltaicznych oraz nasłonecznienia. Rys. 1 przedstawia zmienność dobową generacji energii elektrycznej w miesiącu sierpnie 2022 (31 dni). Rys.2 przedstawia zaś zmienność dobową generacji energii elektrycznej w miesiącu lutym 2022 (28 dni).

### Wybór zestawu zmiennych wejściowych do modeli prognostycznych oraz budowa dodatkowych zmiennych wejściowych

Jako zmienne wejściowe do modeli prognostycznych (kompletny zestaw) wybrano wartości cofnięte szeregu czasowego generacji energii z elektrowni słonecznej, nasłonecznienia, temperatury powietrza oraz prędkości wiatru. Zakres wartości cofniętych wynikał z analizy korelacji danej szeregu czasowego ze zmienną wyjściową. Dodatkowymi zmiennymi wejściowymi były: marker sezonowości (miesiąc – liczba z zakresu 1-12), godzina (liczba z zakresu 1-24) oraz wskaźnik wskazujący na prawdopodobną tendencją rosnącą generacji (sygnatura 1) dla okresów do południa oraz wskaźnik wskazujący na prawdopodobny tendencją malejącą generacji (sygnatura -1) dla okresów od południa. Wykreowano również dodatkową zmienną w postaci wartości wygładzonej w celu potencjalnego zmniejszenia składnika losowego procesu. Warto zauważyć, że nowa, wykreowana zmienna wejściowa ma największą korelację ze zmienną wyjściową (0,9274). W Tabeli 2 przedstawiono wybrane zmienne wejściowe, ich kody oraz wartości korelacji liniowej Persony ze zmienną wyjściową – EG(T). Oznaczenie T-1 oznacza wartość cofniętą w stosunku do okresu prognozy T o 15 minut (1 okres wstecz).

Tabela 2. Wyselekcjonowane zmienne wejściowe, ich kody oraz wartości korelacji liniowej Persony ze zmienną wyjściową – EG(T).

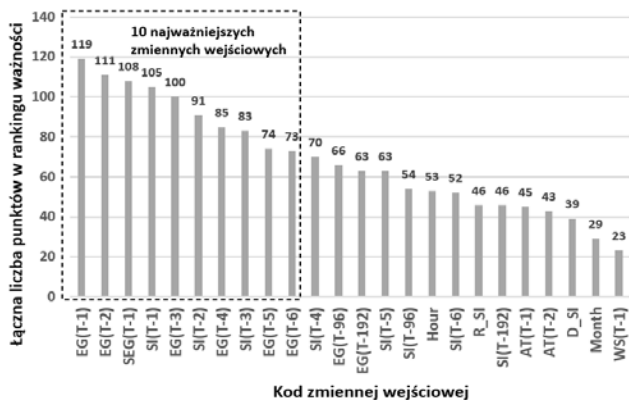
Opis zmiennej wejściowej	Kod	R
Miesiąc	Month	-0,1155
Godzina	Hour	0,3800
Okres wzrostu nasłonecznienia	R SI	-0,2406
Okres spadku nasłonecznienia	D SI	-0,2406
Wygładzona generacja w okresie T-1 [p.u.]	SEG(T-1)	0,9274
Generacja w okresie T-1 [p.u.]	EG(T-1)	0,9245
Generacja w okresie T-2 [p.u.]	EG(T-2)	0,8820
Generacja w okresie T-3 [p.u.]	EG(T-3)	0,8460
Generacja w okresie T-4 [p.u.]	EG(T-4)	0,8103
Generacja w okresie T-5 [p.u.]	EG(T-5)	0,7729
Generacja w okresie T-6 [p.u.]	EG(T-6)	0,7373
Generacja w okresie T-96 [p.u.]	EG(T-96)	0,6719
Generacja w okresie T-192 [p.u.]	EG(T-192)	0,6030
Nasłonecznienie w okresie T-1 [W/m <sup>2</sup> ]	SI(T-1)	0,8818
Nasłonecznienie w okresie T-2 [W/m <sup>2</sup> ]	SI(T-2)	0,8406
Nasłonecznienie w okresie T-3 [W/m <sup>2</sup> ]	SI(T-3)	0,8054
Nasłonecznienie w okresie T-4 [W/m <sup>2</sup> ]	SI(T-4)	0,7684
Nasłonecznienie w okresie T-5 [W/m <sup>2</sup> ]	SI(T-5)	0,7328
Nasłonecznienie w okresie T-6 [W/m <sup>2</sup> ]	SI(T-6)	0,6960
Nasłonecznienie w okresie T-96 [W/m <sup>2</sup> ]	SI(T-96)	0,6566
Nasłonecznienie w okresie T-192 [W/m <sup>2</sup> ]	SI(T-192)	0,5862
Temperatura powietrza w okresie T-1 [°C]	AT(T-1)	0,3899
Temperatura powietrza w okresie T-2 [°C]	AT(T-2)	0,3815
Prędkość wiatru w okresie T-1 [m/s]	WS(T-1)	-0,0720

### Analiza ważności zmiennych wejściowych

Kolejnym krokiem badań było wykonanie prognoz z wykorzystaniem trzech modeli nieliniowych uczenia maszynowego (sieć neuronowa typu MLP, las losowy (RF-Random Forest), drzewa decyzyjne wzmocnione gradientowo (GBDT – Gradient Boosted Decision Trees) oraz jednego modelu liniowego - regresja liniowa wieloraka (MLR – Multiple Linear Regression)). Następnie wykonano dla każdego z modeli analizę ważności/wrażliwości wskazującą ważność poszczególnych zmiennych wejściowych. Badania poprzedziły dodatkowe preprocessing – usunięcie z szeregu czasowych okresów od wschodu do zachodu słońca. Taki zabieg „upraszcza” zadanie modelom prognostycznym ponieważ prognozy dla okresów o zerowej generacji są pomijane.

Tabela 3. Ranking ważności 24 zmiennych wejściowych na podstawie pięciu różnych analiz ważności.

Kod zmiennej	R	MLP	RF	GBDT	MLR	Suma punktów
EG(T-1)	23	<b>24</b>	<b>24</b>	<b>24</b>	<b>24</b>	119
EG(T-2)	22	22	21	22	24	111
SEG(T-1)	<b>24</b>	23	23	23	15	108
SI(T-1)	21	20	22	21	21	105
EG(T-3)	20	17	20	20	23	100
SI(T-2)	19	21	17	19	15	91
EG(T-4)	18	12	19	18	18	85
SI(T-3)	17	18	16	17	15	83
EG(T-5)	16	14	13	16	15	74
EG(T-6)	14	15	15	14	15	73
SI(T-4)	15	9	18	13	15	70
EG(T-96)	11	5	11	15	24	66
EG(T-192)	9	10	9	11	24	63
SI(T-5)	13	11	14	10	15	63
SI(T-96)	10	7	10	12	15	54
Hour	5	19	7	7	15	53
SI(T-6)	12	3	12	8	17	52
R_SI	4	13	2	3	24	46
SI(T-192)	8	6	8	9	15	46
AT(T-1)	7	4	6	6	22	45
AT(T-2)	6	8	5	4	20	43
D_SI	3	16	3	2	15	39
Month	2	2	4	5	16	29
WS(T-1)	1	1	1	1	19	23



Rys.3 Ranking ważności 24 zmiennych wejściowych.

Na podstawie wykonanych analiz ważności/wrażliwości oraz biorąc również pod uwagę wartości współczynnika korelacji liniowej Pearsona z poszczególnymi zmiennymi wejściowymi opracowano końcowy ranking ważności. Dla każdego z modeli wartości ważności zostały posortowane malejąco a następnie ponumerowane (maksymalnie 24 punkty dla zmiennej najważniejszej). W Tabeli 3 oraz na Rys. 3. przedstawiono końcowy ranking ważności 24 zmiennych wejściowych na podstawie pięciu różnych analiz ważności.

Dla wszystkich modeli uczenia maszynowego zmienna EG(T-1) czyli ostatnia wartość sprzed okresu prognozy była najważniejszą zmienną wejściową. Jedynie w analizie wartości współczynników korelacji najważniejszą zmienną była wartość wygładzona z ostatniego okresu SEG(T-1). W przypadku ostatniej zmiennej w rankingu – prędkość wiatru w ostatnim okresie WST(T-1) wszystkie metody jednoznacznie wskazały, że jest to zmienna najmniej przydatna. Na uwagę zwraca również fakt, że dla modelu MLP zmienne o kodach R\_SI oraz D\_SI (sygnatury kierunku zmian prognozowanego procesu – wzrost/spadek) były znacznie ważniejsze niż dla pozostałych modeli prognostycznych. Podobne zjawisko wystąpiło dla zmiennej o kodzie Hour. W przypadku lasu losowego oraz drzew decyzyjnych wzmocnionych gradientowo wystąpiło silne podobieństwo w ważności poszczególnych zmiennych wejściowych – oba modele mają pewne cechy wspólne oraz są metodami zespołowymi.

### Prognozy generacji energii przez elektrownię słoneczną wybranymi technikami uczenia maszynowego

Modele prognostyczne zostały utworzone z wykorzystaniem wszystkich zaproponowanych zmiennych objaśniających. Jako metodę odniesienia wykorzystano metodę naiwną (NAIVE) z zastosowaniem tylko jednej zmiennej objaśniającej) - EG(T-1), czyli ostatniego znanego w danym momencie pomiaru. Prognozy były wykonywane jednokrotnie na 15 min wprzód z granulacją 15 min.

Zebrane dane zostały podzielone na zbiory treningowe, walidacyjne i testowe tak by odzwierciedlić w prognozach charakter czterech sezonów klimatycznych. Ze względu na dostęp w momencie wykonywania badań do danych jedynie z okresu jednego roku nie był możliwy podział danych na np. osobne roczne lub wieloletnie okresy do celów treningu, walidacji oraz testu jakości modeli. Wiosna trwała od pierwszego marca do pierwszego czerwca, lato kolejno do pierwszego września, jesień do pierwszego grudnia, a pozostała część roku była traktowana jako zima. Ostatni tydzień każdego sezonu był przypisany do danych testowych, zaś pozostałe dane zostały podzielone na treningowo-walidacyjne w proporcji 80 % do 20%. Dane testowe stanowiły więc około 17 % całości dostępnego rocznego zbioru danych. Zastosowane miary jakości modeli opisują

wzory (1), (2) oraz (3). Charakterystykę poszczególnych miar oraz metod prognoz czytelnik może znaleźć w literaturze [13-15].

$$(1) \quad nRMSE [j.w.] = \sqrt{\frac{1}{c_{norm}} \frac{1}{n} \sum_{i=1}^n \left( y_i - \hat{y}_i \right)^2}$$

$$(2) \quad nMAE [j.w.] = \frac{1}{n} \sum_{i=1}^n \frac{1}{c_{norm}} \left| y_i - \hat{y}_i \right|$$

$$(3) \quad nAPE \max [\%] = \max_{i=1, \dots, n} \frac{1}{c_{norm}} \left| y_i - \hat{y}_i \right| \cdot 100\%$$

gdzie:  $c_{norm}$  – współczynnik normalizacji (moc znamionową PV),

$\hat{y}_i$  – wartość przewidywana,  $y_i$  – wartość rzeczywista,  $n$  – liczba próbek.

Wśród miar oceny jakości modeli, nRMSE wybrano ze względu na czułość tej miary na błędy znacząco duże. Dla odmiany, nMAE koncentruje się na błędzie średnim, zaś nAPEmax jest miarą prezentującą maksymalny oczekiwany poziom niedokładności. Zastosowanie trzech miar jakości oceny modeli umożliwiło wieloaspektowe spojrzenie na uzyskane wyniki przez analizowane modele prognostyczne.

Metoda MLR była testowana z wykorzystaniem członu stałego oraz bez członu stałego. Lepsze wyniki uzyskano dla modeli bez członu stałego. Dla sieci MLP testowano model z jedną warstwę ukrytą o liczbie neuronów od 10 do 30, funkcją aktywacji w warstwie ukrytej typu tanh, sigmoidalną lub wykładniczą. W warstwie wyjściowej zastosowano liniową funkcję aktywacji. Najlepsze wyniki osiągnięto dla 16 neuronów, funkcji tanh, oraz liczby epok równej 38. Sieć neuronowa MLP wykorzystywała optymalizator BFGS, jeden neuron wyjściowy z liniową funkcją aktywacji oraz inicjalizacją wag sieci zgodnie z rozkładem Gaussa. Dla modelu GBDT testowano liczby drzew wynoszące 50, 60, 70, 85 oraz 100, maksymalną głębokość drzewa od 2 do 6, współczynnik uczenia równy 0,1, 0,15, 0,2 oraz 0,25. Najlepsze wyniki osiągnięto przy liczbie drzew, maksymalnej głębokości drzew i współczynniku uczenia równym kolejno 85, 3 oraz 0,1. W przypadku lasów losowych testowano liczbę drzew od 50 do 300, minimalną liczbę próbek w węźle powodującą podział równą 50, 100, 200 oraz 400, maksymalną głębokość wynoszącą 5, 10 oraz 15, maksymalną liczbę węzłów równą 100 oraz 200. Najlepsze wyniki osiągnięto przy tych parametrach równych odpowiednio 300, 100, 10 oraz 100. Wyniki prognoz przedstawiono w Tabeli 4.

Tabela 4. Wyniki uzyskane dla wybranych modeli prognostycznych na zbiorze testowym

Model	nRMSE [j.w.]	nMAE [j.w.]	nAPEmax [%]
RF	0.02123	0.01026	18.7999
MLP	0.02160	0.01007	18.5677
GBDT	0.02164	0.01090	18.21088
MLR	0.02233	0.01114	20.2689
NAIVE	0.02374	0.00988	20.2918

### Podsumowanie i wnioski

Na podstawie opracowanego rankingu ważności zmiennych wejściowych można wnioskować, że najważniejszymi zmiennymi wejściowymi dla modeli prognostycznych są wartości generacji energii elektrycznej oraz wartości natężenia promieniowania słonecznego z kilku ostatnich 15-minutowych okresów przed okresem prognozy. Dodatkowo, wygładzona wartość generacji energii w okresie T-1 rów-

niez należy do najważniejszych zmiennych wejściowych. Z drugiej strony, najmniej wartościowymi zmiennymi wejściowymi są prędkość wiatru oraz wskaźnik sezonowości (kod Month).

Obserwując kolejne cofnięcia zmiennych wejściowych, można zauważyć różnice w tym jak modele wartościują znaczenie poszczególnych zmiennych – metody drzewiaste (GBDT, RF) za ważniejsze uznają nasłonecznienie cofnięte o 3 okresy a MLP o 2 okresy. Interesującą obserwacją było też to, że MLP jest wrażliwa na podanie jawnych informacji o fragmencie cyklu dobowego – godziny i markerów spadku oraz wzrostu nasłonecznienia, podczas gdy dla RF i GBDT nie są to informacje ważne. Różnice w ważności informacji mogą świadczyć o potencjale łączenia zbadanych modeli prognostycznych w metody zespolone.

Analizując uzyskane wyniki prognoz można zauważyć, że prognozy charakteryzują się dużą dokładnością, na poziomie około 1% nMAE. Zastosowanie kilku miar dokładności umożliwiło równoczesne zmniejszenie błędów znacząco dużych modeli predykcyjnych (nRMSE) oraz oczekiwanej maksymalnej niedokładności prognoz nAPEmax. Największą poprawę uzyskał model MLP, który zmniejszył błąd nRMSE o 9% oraz nAPEmax o 8.5% w stosunku do metody naiwnej. Metody RF, GBDT oraz MLR bardziej koncentrowały się na redukcji błędów dużych, niż na redukcji błędu średniego. Model liniowy MLR miał większy błąd nMAE o prawie 13%, a model nieliniowy GBDT miał błąd większy o 10.2%. W porównaniu, błędy nMAE modeli MLP i RF okazały się większe jedynie o odpowiednio 1.9% i 3.8% w stosunku do metody naiwnej. Jednocześnie modele lasów losowych wykazały przy tym największą poprawę błędu nRMSE (o 10.6% w stosunku do metody naiwnej). Świadczy to o tym, że zarówno model MLP jak i model RF mogą stanowić skuteczne narzędzie optymalizacji wielokryterialnej dla analizowanego problemu. W odróżnieniu od tych modeli, modele GBDT oraz MLR kompensują poprawę błędów dużych, wzrostem wartości błędu średniego.

*Niniejszy referat został sfinansowany ze środków Narodowego Centrum Badań i Rozwoju, przeznaczonych na realizację projektu badawczego pt. „Cyfrowa Ścieżka dla Planowania i Eksploatacji Zrównoważonych Sieci Elektroenergetycznych, Produktów i Społeczności” (akronim: DIEGO). Projekt DIEGO jest finansowany za pośrednictwem ERA-Net Smart Energy Systems on Digital Transformation for Green Energy Transition (EnerDigi).*

**Autorzy:** dr hab. inż. Paweł Piotrowski, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, Polska, E-mail: pawel.piotrowski@pw.edu.pl; dr inż. Marcin Kopyt, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, Polska, E-mail: marcin.kopyt@pw.edu.pl; dr inż. Łukasz Rokicki, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, Polska, E-mail: lukasz.rokicki@pw.edu.pl

## LITERATURA

- [1] Pardo, Nicolás, and José Antonio Moya. "Prospective Scenarios on Energy Efficiency and CO2 Emissions in the European Iron & Steel Industry." *Energy (Oxford)* 54 (2013): 113-128
- [2] Boloy Ronney, A.M., da Cunha, R.A., Rios, E.M., de Araújo Santos Martins Janaína, Soares, L.O., de Sá Machado, V.A. & de Moraes, D.R. 2021, "Waste-to-Energy Technologies Towards Circular Economy: a Systematic Literature Review and Bibliometric Analysis", *Water, Air and Soil Pollution*, vol. 232, no. 7
- [3] Further Improvements of Energy Efficiency in Industry. Luxembourg: Publications Office, 2022. Web
- [4] Kiss, Tibor, and Steve Popovics. Evaluation on the Effectiveness of Energy Policies – Evidence from the Carbon Reductions in 25 Countries. *Renewable & sustainable energy reviews* 149 (2021): 111348. Print
- [5] Bersalli, Germán, Philippe Menanteau, and Jonathan El-Methni. Renewable Energy Policy Effectiveness: A Panel Data Analysis across Europe and Latin America. *Renewable & sustainable energy reviews* 133.November (2020): 110351. Print
- [6] Sun, Yanlei, Zhanlei Xing, and Guojun Liu. Achieving Resilient Cities Using Data-Driven Energy Transition: A Statistical Examination of Energy Policy Effectiveness and Community Engagement. *Sustainable cities and society* 101 (2024): 105155. Print
- [7] Narciso, Diogo A. C, and F. G Martins. "Application of Machine Learning Tools for Energy Efficiency in Industry: A Review." *Energy Reports* 6 (2020): 1181-1199. Web
- [8] Zuo, Hongyan et al. Investigation on Energy-Effectiveness Enhancement of Medium-Frequency Induction Furnace Based on an Adaptive Chaos Immune Optimization Algorithm with Mutative Scale. *Processes* 10.3 (2022): 491. Print
- [9] Kumar, Anil, and Om Prakash. Effect Of Insulation On Energy And Exergy Effectiveness Of A Solar Photovoltaic Panel Incorporated Inclined Solar Still—An Experimental Investigation. *Green Energy and Technology*. Singapore: Springer Singapore Pte. Limited, 2019. 275 292. Print. *Green Energy and Technology*
- [10] Piotrowski P., Parol M., Kapler P., Fetliński B., Advanced Forecasting Methods of 5-Minute Power Generation in a PV System for Microgrid Operation Control, *Energies* 2022, 15(7), <https://doi.org/10.3390/en15072645>, -23
- [11] Piotrowski P., Analiza doboru zmiennych w zadaniu prognozowania ultrakrótkoterminowego produkcji energii elektrycznej w systemach fotowoltaicznych, *Przegląd Elektrotechniczny*, 90 (2014), nr 4, 5-9
- [12] Kopyt M., Power Flow Forecasts: A Status Quo Review. Part 1: RES Generation Prediction, *Przegląd Elektrotechniczny*, 96(2020), no. 11, 1-4
- [13] Baczyński D., Parol M., Piotrowski P., Współczesne problemy prognozowania w elektroenergetyce. *Zagadnienia wybrane*, Pod redakcją naukową Mirosława Parola, OWPW, (2020)
- [14] Baczyński D., Parol M., Piotrowski P., Wybrane zagadnienia prognozowania produkcji energii elektrycznej z wykorzystaniem odnawialnych nośników energii, Pod redakcją naukową Mirosława Parola, OWPW, (2023)
- [15] Dobrzańska I., Daśal K., Łyp J., Popławski T., Sowiński J., Prognozowanie w elektroenergetyce *Zagadnienia wybrane*. Wydawnictwo Politechniki Częstochowskiej. Częstochowa (2002)