

# Zastosowanie metod głębokiego uczenia w systemie ładowania samochodów elektrycznych z użyciem źródeł odnawialnych i magazynów energii

**Streszczenie.** Optymalizacja funkcjonowania stacji ładowania pojazdów elektrycznych (PEV) w zmiennych warunkach atmosferycznych oraz zmiennym zapotrzebowaniu na energię jest kluczowym wyzwaniem w kontekście rozwoju infrastruktury PEV. W opracowaniu przedstawiono wyniki zastosowania modelu głębokiego uczenia (DL), który uwzględniając różne parametry pozwala dostosować zasoby stacji ładowania do optymalnego funkcjonowania w czasie rzeczywistym. Eksperymentalne testy przeprowadzono na danych symulacyjnych, uwzględniając lokalne warunki pogodowe i zachowania użytkowników pojazdów elektrycznych.

**Abstract.** Optimizing the operation of Plug in Electric Vehicle (PEV) Charging Stations in changing weather conditions and changing energy demand is a key challenge in the context of the development of PEV infrastructure. The study presents the results of the use of a deep learning (DL) model, which, taking into account various parameters, allows the charging station resources to be adjusted to optimal functioning in real time. Experimental tests were performed on simulation data, taking into account local weather conditions and the behavior of electric vehicle users. (**Application of deep learning methods in an electric car charging system using renewable sources and energy storage**)

**Słowa kluczowe:** pojazdy elektryczne, elektrownie fotowoltaiczne, farmy wiatrowe, magazyny energii, system elektroenergetyczny, inteligentne sieci ładowania.

**Keywords:** plug-in electric vehicles, photovoltaic power sources, wind farms, energy storage facilities, energy distribution system, intelligent charging networks

## Wprowadzenie

Dynamiczny rozwój elektromobilności powoduje wzrost zapotrzebowania na energię elektryczną do ładowania pojazdów elektrycznych (PEV) [1]. Związany z tym wzrost obciążenia sieci elektroenergetycznych może zostać ograniczony przez wprowadzenie autonomicznych stacji ładowania PEV. Autonomiczne stacje ładowania muszą działać w oparciu o infrastrukturę odnawialnych źródeł energii skojarzonych z jej magazynowaniem w oparciu o efektywne systemy optymalizujące ich pracę [2]. Masowe podłączanie pojazdów PEV do sieci dystrybucyjnych będzie miało znaczący wpływ na ich obciążenie i zapotrzebowanie na energię elektryczną, jeśli ładowanie akumulatorów PEV nie będzie odpowiednio skoordynowane lub przynajmniej w części wydzielone do systemów autonomicznych [3]. Prognozowanie obciążenia dla ładowania PEV ma kluczowe znaczenie dla eksploatacji stacji ładowania [4].

Inteligentne algorytmy zarządzania ładowaniem pojazdów elektrycznych mogą znacząco zmniejszyć obciążenie sieci energetycznej i umożliwić lepszą integrację odnawialnych źródeł energii dla danej lokalizacji. Przeprowadzone już badania dotyczące projektowania inteligentnych sieci ładowania wykorzystujące algorytmy do zarządzania popytem na energię elektryczną zweryfikowały wykonalność zastosowań i wyższość stosowania metod DL w zakresie prognozowania obciążenia elektrycznego [5].

## Metodologia i problemy do rozwiązania

W niniejszym opracowaniu zostanie omówione zastosowanie systemu optymalizującego funkcjonowanie stacji ładowania PEV, bazującego na modelu głębokiego uczenia się (DL) do optymalizacji systemu składającego się ze źródeł energii odnawialnej, magazynu energii oraz stacji ładowania pojazdów elektrycznych.

Metody DL znalazły zastosowanie w optymalizacji ładowania pojazdów elektrycznych ze względu na ich zdolność do modelowania złożonych zależności, analizy danych historycznych oraz dostosowywania się do zmieniających się warunków. Wykorzystanie głębokiego uczenia ze wzmocnieniem (Deep Reinforcement Learning) do optymalizacji

ładowania pojazdów elektrycznych zaproponowano w [6]. W opracowaniu przedstawiono model wykorzystania agenta uczonego w środowisku symulacyjnym do podejmowania decyzji dotyczących ładowania EV w celu minimalizacji kosztów i maksymalizacji wydajności. Z kolei w [7] zaproponowano zastosowanie Deep Q-Learning (DL-Q) do optymalizacji harmonogramu ładowania pojazdów elektrycznych w inteligentnych sieciach energetycznych. Wykorzystano sieć neuronową do uczenia modelu, który przewidywał wartość oczekiwaną nagrody dla różnych strategii ładowania. Zastosowanie konwolucyjnych sieci neuronowych (CNN) do przewidywania popytu na energię elektryczną oraz do generowania optymalnego harmonogramu ładowania z uwzględnieniem ograniczeń sieciowych przedstawiono w modelu opartym na DL do optymalizacji ładowania PEV [8].

Mimo znacznego wzrostu produkcji energii odnawialnej nie udaje się wyeliminować jej głównego mankamentu, jakim jest niestabilność generacji energii elektrycznej z jej podstawowych źródeł, którymi są promieniowanie słoneczne i wiatr. Produkcja energii fotowoltaicznej (PV) rośnie w stosunkowo szybkim tempie, jednak jej immanentną cechą jest okresowość wytwarzania i zmienność produkcji zależna od pory dnia i warunków atmosferycznych [9].

Problemem, z jakim mamy do czynienia w rozwoju stacji zasilania PEV, jest zapewnienie zasilania tych stacji w energię ze źródeł odnawialnych (RES) w sposób, który możliwie najmniej ingeruje w zasoby środowiska naturalnego oraz może być stabilny. Takim rozwiązaniem mogą być stacje ładowania PEV funkcjonujące w oparciu o własne lub nieodległe zasoby RES. Dla stabilnego funkcjonowania takiego systemu niezbędne jest określenie wielkości poszczególnych RES i ich konfiguracji w stosunku do danej wielkości stacji ładowania i szacowanego obciążenia jej przez PEV.

W niniejszym opracowaniu scharakteryzowane jest działanie modelu, który w oparciu o głębokie uczenie maszynowe może być użytecznym narzędziem do przewidywania parametrów stacji ładowania pojazdów elektrycznych na pod-

stawie zmiennych danych wejściowych uwzględniających zmienność pogody.

### Optimalizacja funkcjonowania stacji ładowania pojazdów PEV - podstawowe koncepcje oraz wyzwania i korzyści

Optimalizacja funkcjonowania stacji ładowania PEV działającej w zmiennych warunkach atmosferycznych i przy zmieniającym się zapotrzebowaniu na energię stanowi kluczowe wyzwanie w kontekście rozwoju infrastruktury pojazdów elektrycznych. W niniejszym opracowaniu proponujemy zastosowanie modelu głębokiego uczenia (DL), który uwzględnia lokalizację stacji ładowania, dostępność odnawialnych źródeł energii, zapotrzebowanie na energię przez pojazdy oraz magazynowanie energii, które równoważy system w sytuacjach niedoboru produkowanej energii w stosunku do zapotrzebowania. Model ten wykorzystując odpowiednią architekturę będzie przewidywać zmienne warunki atmosferyczne i elastycznie dostosowywać prędkość ładowania w czasie rzeczywistym. Eksperymentalne testy przeprowadzono na danych symulacyjnych, uwzględniając lokalne warunki pogodowe i zachowania użytkowników pojazdów elektrycznych.

Istotnym zadaniem jest dobranie i odpowiednie wytrenowanie algorytmu, który obliczy gradient funkcji straty względem parametrów modelu jak poniżej:

$$\nabla L_{\theta_j} = \partial L / \partial \theta_j = \sum_i \partial C_i / \partial \theta_j * w_i$$

gdzie:

- $\partial C_i / \partial \theta_j$  - pochodna składnika  $C_i$  funkcji straty względem parametru  $\theta_j$

$w_i$  - waga składnika  $C_i$

### DL w optymalizacji ładowania PEV

Metody DL znalazły zastosowanie w optymalizacji ładowania pojazdów elektrycznych ze względu na ich zdolność do modelowania złożonych zależności, analizy danych historycznych oraz dostosowywania się do zmieniających się warunków. Wykorzystanie głębokiego uczenia ze wzmocnieniem (DRL) do optymalizacji ładowania pojazdów elektrycznych zaproponowano w modelu do podejmowania decyzji dotyczących ładowania PEV w celu minimalizacji kosztów i maksymalizacji wydajności. Zastosowanie Deep Q-Learning (DL-Q) do optymalizacji harmonogramu ładowania pojazdów elektrycznych w inteligentnych sieciach energetycznych w modelu przewidującym wartość oczekiwaną nagrody dla różnych strategii ładowania. Konwolucyjne sieci neuronowe (CNN) do estymacji popytu na energię elektryczną oraz optymalizacji harmonogramu ładowania z uwzględnieniem ograniczeń sieciowych przedstawiono w [8]. Mimo znacznego wzrostu produkcji energii odnawialnej nie udaje się wyeliminować jej głównego mankamentu, jakim jest niestabilność generacji i zapotrzebowania na energię elektryczną.

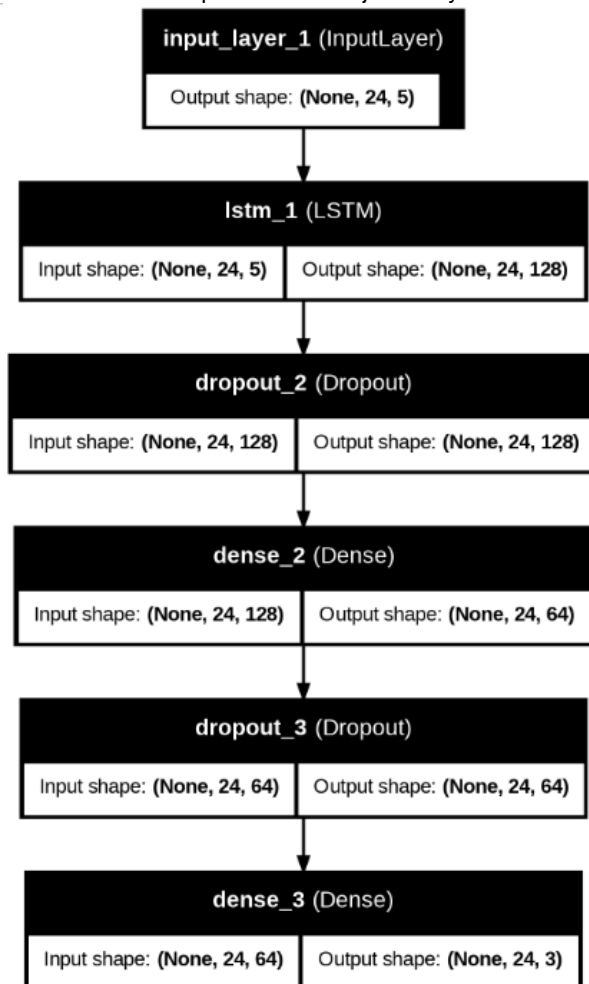
Optimalizacja ładowania PEV z uwzględnieniem RES pozwoli łagodzić skutki rosnącego popytu na energię elektryczną ze strony EV poprzez redukcję obciążenia sieci energetycznej.

Przykłady badań dotyczących integracji RES ze stacjami ładowania to optymalizacja lokalizacji PL w oparciu o dostępność RES [10][11] oraz wykorzystanie energii słonecznej do ładowania EV przez fotowoltaikę [12].

### Model do optymalizacji systemu

Istotnym zagadnieniem jest zoptymalizowanie pracy generatorów energii opartych na RES i magazynu energii stabilizującego zasilanie w energię stacji ładowania na rzecz zmiennego zapotrzebowania na energię ze strony EV. Istotnym celem była taka konstrukcja modelu, która pozwoli na jego dopasowanie do mocy PV, mocy turbiny i pojemności magazynu.

Architektura modelu przedstawiona jest na rysunku 1.



Rys. 1. Architektura modelu DL

Architektura modelu jest głęboką siecią neuronową składającą się z kilku warstw w pełni połączonych (dense), z elementami regularyzacji [13] w postaci warstw dropout. Dane wejściowe reprezentują sekwencje danych wejściowych o 5 cechach (czas, liczba pojazdów, promieniowanie słoneczne, prędkość wiatru, moc PV).

- Warstwy LSTM: dwie warstwy LSTM do przetwarzania sekwencji czasowych. Po każdej z nich występuje warstwa Dropout dla regularyzacji.
- Warstwy gęste Dense: dwie warstwy gęste do dalszego przetwarzania cech. I również warstwy Dropout.
- Warstwa wyjściowa: ostatnia warstwa gęsta, która produkuje przewidywania dla 3 cech wyjściowych (moc turbiny, ładowanie PEV, pojemność magazynu).
- Dane wyjściowe: reprezentują sekwencje danych wyjściowych o 3 cechach.

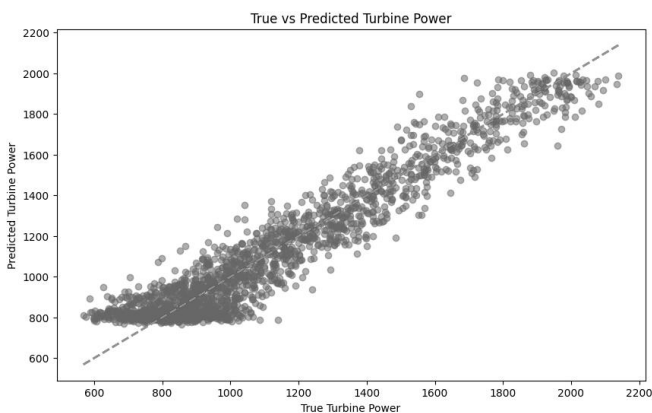
Szczegółowy opis wpływu każdej warstwy na przetwarzanie danych w modelu:

1. Warstwy LSTM, które umożliwiają modelowi uczenie się długoterminowych zależności w danych czasowych.
2. Warstwy Dropout, które zapobiegają przeuczeniu i poprawiają generalizację modelu.
3. Warstwy gęste, które przetwarzają cechy wyekstrahowane przez LSTM i modelują nieliniowe zależności.
4. Warstwa wyjściowa, która produkuje końcowe przewidywania.

Parametry architektury modelu:

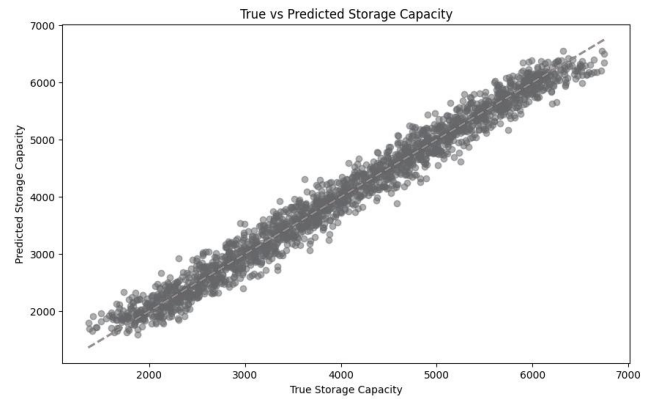
1. Warstwa wejściowa: przyjmuje sekwencje danych o 5 cechach.
2. Warstwy LSTM: dwie warstwy LSTM, każda z bramkami wejściowymi, zapominania i wyjściowymi używającymi funkcji sigmoidalnej ( $\sigma$ ). Stan komórki i stan ukryty używają funkcji tanh.
3. Warstwy Dropout: trzy warstwy Dropout, każda z prawdopodobieństwem wyłączenia neuronu  $p = 0.2$ . Umieszczone po każdej warstwie LSTM i po pierwszej warstwie Dense. Warstwy Dense: pierwsza warstwa Dense z aktywacją ReLU.
4. Warstwa wyjściowa z liniową aktywacją (brak funkcji aktywacji). Optymalizator Adam: z kluczowymi parametrami: Współczynnik uczenia: 0.001.  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$  (parametry dla momentów pierwszego i drugiego rzędu).  $\epsilon = 1e-7$  (mała wartość zapobiegająca dzieleniu przez zero). Przepływ danych:
5. Optymalizator Adam jest połączony ze wszystkimi warstwami, co oznacza, że aktualizuje parametry całego modelu.

Architektura modelu pozwala na hierarchiczne uczenie się cech, od prostych wzorców czasowych po złożone zależności między różnymi parametrami systemu ładowania pojazdów elektrycznych i produkcji energii odnawialnej. Warstwy LSTM umożliwiają modelowi uczenie się długoterminowych zależności w danych czasowych. Warstwy Dropout zapobiegają przeuczeniu i poprawiają generalizację modelu. Warstwy gęste przetwarzają cechy wyekstrahowane przez LSTM i modelują nieliniowe zależności. A warstwa wyjściowa produkuje końcowe przewidywania. Dopasowanie modelu przedstawiają poniższe wykresy.



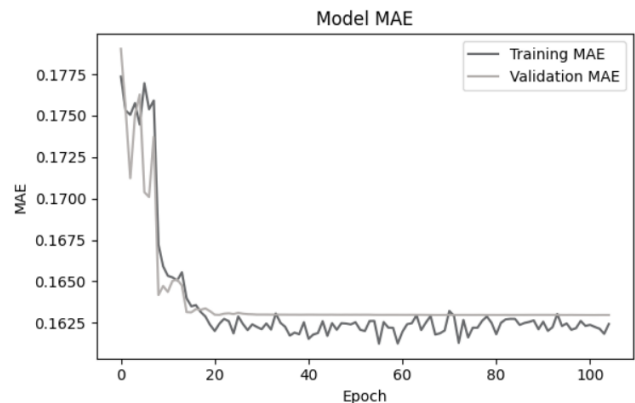
Rys. 2. Korelacja dla mocy turbiny wiatrowej

Wyniki korelacji zmiennych oczekiwanych z rzeczywistymi.



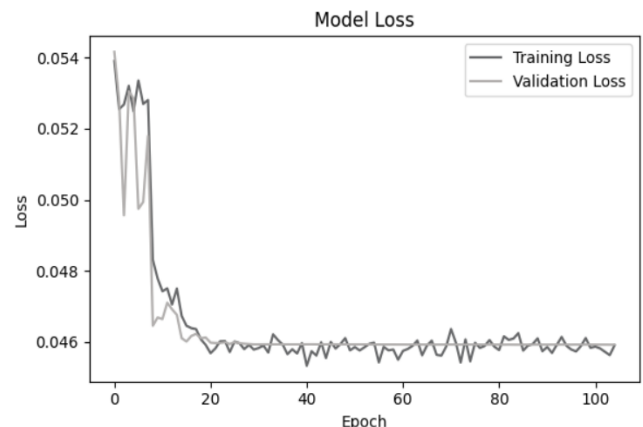
Rys. 3. Korelacja dla magazynu energii

Wysokie współczynniki korelacji sugerują, że przewidywania modelu dobrze oddają zależność między zmiennymi wejściowymi a wynikami.



Rys. 4. MAE - średnia wartość bezwzględna różnicy między przewidywanymi, a rzeczywistymi wartościami

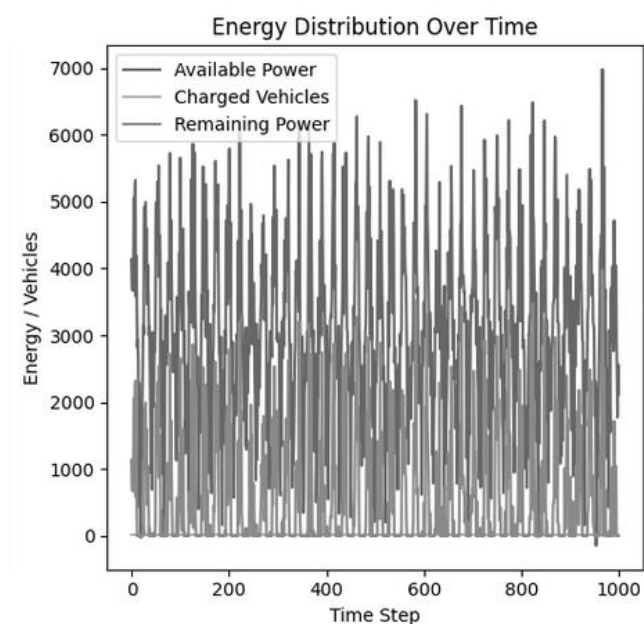
Niskie MAE (Mean Absolute Error) oznaczają, że średnia wartość bezwzględna różnicy między przewidywanymi, a rzeczywistymi wartościami jest mała, co wskazuje na dokładność modelu.



Rys. 5. Funkcja straty - miara różnicy między przewidywaniami modelu a rzeczywistymi wartościami

Funkcja straty to kluczowy element oceny, jak dobrze model działa podczas procesu trenowania. Jest to miara różnicy między przewidywaniami modelu a rzeczywistymi wartościami. Im niższa wartość funkcji straty, tym lepiej model uczy się dopasowywać do danych. Systematyczny spadek wartości strat zarówno dla danych treningowych, jak i walidacyjnych sugeruje, że model dobrze się uczy i unika przeuczenia.

Wyniki wskazują, że opracowany model może być przydatny przy badaniach dotyczących lokalizacji i konfiguracji stacji ładowania PEV z RES.



Rys. 6. Rozkład energii w czasie

Rozkład energii między dostępną moc, naładowane pojazdy i pozostałą moc. Widoczne są regularne wzorce, które odzwierciedlają cykle dzienne.

Model jest oparty na symulacji dynamicznej pozwoli określić optymalną strukturę składników RES oraz magazynu energii dla stacji ładowania charakteryzującej się określoną lokalizacją oraz obciążeniem przez ładowane pojazdy.

Model uwzględnia zmienność pogody, ruchu drogowego i zużycia energii, co pozwala na optymalizację procesu ładowania pojazdów oraz zarządzanie dostępnymi RES i magazynem energii. Analiza wyników programu umożliwi śledzenie zmian poziomów naładowania baterii w czasie, liczby ładowanych pojazdów oraz zużycie energii. Model pomaga w zrozumieniu, jak można optymalizować procesy związane z ładowaniem pojazdów elektrycznych i wykorzystywać energię odnawialną oraz magazyn energii.

### Podsumowanie

Sieci ładowania PEV to kluczowy element w systemie transportu opartym o PEV. Zrównoważenie popytu na energię elektryczną w kontekście rosnącej liczby samochodów elektrycznych będzie wyzwaniem dla zarządzających sieciami elektroenergetycznymi.

Skojarzenie RES, takich jak farmy PV czy elektrownie wiatrowe, ze stacją ładowania PEV pozwoli zwiększyć udział odnawialnych źródeł energii w systemie energetycznym bez konieczności ponoszenia dodatkowych nakładów na rozbudowę infrastruktury przesyłowej.

W artykule zawarto wstępne wyniki uzyskane z modelu opartego na DL, który może być narzędziem do określenia optymalnych stacji ładowania pojazdów zintegrowanych z RES. Wyniki wskazują, że takie modele mogą być niezbędne przy projektowaniu sieci stacji ładowania przy drogach szybkiego ruchu oraz oddalonych od dużych źródeł energii.

Wyniki wskazują na skuteczność proponowanego modelu w minimalizacji wielkości magazynu energii i zaspokajaniu potrzeb użytkowników pojazdów elektrycznych przy jednoczesnym wykorzystaniu odnawialnych źródeł energii. Przedstawiony model może stanowić podstawę do dalszych badań nad optymalizacją infrastruktury ładowania pojazdów elektrycznych w zmiennych warunkach atmosferycznych.

**Autorzy:** mgr Robert Kaznowski doktorant, Politechnika Wroclawska, Katedra Energoelektryki, ul. Wybrzeże Wyspiańskiego 27, 50-370, E-mail: robert.kaznowski@pwr.edu.pl;  
dr hab. Dariusz Szafranski prof. PWr, Politechnika Wroclawska, Katedra Energoelektryki, ul. Wybrzeże Wyspiańskiego 27, 50-370 Wroclaw, E-mail: dariusz.szafranski@pwr.edu.pl.

### LITERATURA

- [1] Suski, Adam, et al. "E-mobility and Power Systems." (2023).
- [2] Sadeghian, Omid, et al. "A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges." *Journal of Energy Storage* 54 (2022)
- [3] Sanchez, Angel M., et al. "An improved methodology for the hierarchical coordination of PEV charging." *IEEE Access* 7 (2019): 141754-141765.
- [4] Gerossier, A.; Girard, R.; Kariniotakis, G. Modeling and Forecasting Electric Vehicle Consumption Profiles. *Energies* 2019, 12, 1341
- [5] Bouktif, S.; Fiaz, A.; Ouni, A.; Serhani, M. Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies* 2018, 11, 1636.
- [6] Glavic, Mevludin, Raphaël Fonteneau, and Damien Ernst. "Reinforcement learning for electric power system decision and control: Past considerations and perspectives." *IFAC-PapersOnLine* 50.1 (2017): 6918-6927.
- [7] Chifu, Viorica Rozina, et al. "Deep Q-Learning-Based Smart Scheduling of EVs for Demand Response in Smart Grids." *Applied Sciences* 14.4 (2024): 1421.
- [8] Zhu, Juncheng, et al. "Electric vehicle charging load forecasting: A comparative study of deep learning approaches." *Energies* 12.14 (2019): 2692.
- [9] Gupta, P.; Singh, R. PV power forecasting based on data-driven models: A review. *Int. J. Sustain. Eng.* 2021, 14, 1733-1755.
- [10] Zhang, X., Shahidehpour, M., Alabdulwahab, A., & Abusorrah, A. (2016). Hourly electric vehicle charging load forecasting based on the integration of renewable energy resources. *IEEE Transactions on Smart Grid*, 7(6), 2660-2669
- [11] Wang, Haolin, Yongjun Zhang, and Haipeng Mao. "Load forecasting method of EVs based on time charging probability." 2018 International Conference on Power System Technology (POWERCON). IEEE, 2018.
- [12] Wang, Z., Wu, J., Zhao, H., & Liu, Y. (2019). Optimal sizing and placement of electric vehicle charging stations considering the impact of photovoltaic generation. *IEEE Access*, 7, 85581-85590.676
- [13] Polak, A. G., & Mroczka, J. (2007). Regularyzacja identyfikacji obiektów złożonych opisanych modelami nieliniowymi. *Pomiary Automatyka Kontrola*, 53(9 bis), 190-193.