Tomasz Grudniewski[1]
Akademia Bialska im. Jana Pawła II, Biała Podlaska

https://doi.org/10.29316/9788368103373_24

BEZPIECZEŃSTWO ENERGETYCZNE PAŃSTWA A DETEKCJA ANOMALII Z WYKORZYSTANIEM LSTM AUTOENCODER I DANYCH ENTSO-E

NATIONAL ENERGY SECURITY AND THE DETECTION OF ANOMALIES USING LSTM AUTOENCODERS AND ENTSO-E DATA

Streszczenie

Celem rozdziału jest ocena możliwości wykorzystania modelu LSTM Autoencoder do detekcji anomalii w godzinowych danych obciążenia krajowego systemu elektroenergetycznego Polski. Badanie osadzono w kontekście bezpieczeństwa energetycznego państwa, rozumianego jako zdolność do zapewnienia stabilnych dostaw energii oraz wczesnego identyfikowania nietypowych zjawisk mogących wskazywać na błędy danych, zakłócenia techniczne lub zdarzenia systemowe. Materiał badawczy stanowiły publiczne dane ENTSO-E obejmujące obciążenie systemu elektroenergetycznego Polski w latach 2022-2024. Dane poddano oczyszczeniu, normalizacji oraz podziałowi chronologicznemu na zbiory uczące, walidacyjne i testowe. Model

[1] https://orcid.org/0000-0003-3394-8992, e-mail: gisbourne2@gmail.com

uczono rekonstrukcji typowych tygodniowych przebiegów obciążenia, a detekcję oparto na wartości błędu rekonstrukcji. W części testowej zastosowano syntetyczne scenariusze anomalii: skok dodatni, spadek, flatline oraz dryf. Wyniki wskazują, że model najlepiej identyfikuje gwałtowne spadki obciążenia, częściowo wykrywa skoki dodatnie, natomiast słabiej reaguje na zmiany wolno narastające oraz przebiegi typu flatline. Uzyskane rezultaty potwierdzają przydatność podejścia rekonstrukcyjnego jako narzędzia wspierającego monitoring systemu elektroenergetycznego, przy jednoczesnej konieczności walidacji operatorskiej oraz uzupełnienia modelu o dodatkowe zmienne kontekstowe, takie jak pogoda, generacja OZE i prognozy zapotrzebowania.

Słowa kluczowe: bezpieczeństwo energetyczne, system elektroenergetyczny, detekcja anomalii, LSTM Autoencoder, ENTSO-E, obciążenie elektroenergetyczne, sztuczna inteligencja

Abstract

The aim of this chapter is to assess the potential of using the LSTM Autoencoder model for anomaly detection in hourly load data from Poland's national power system. The study is set within the context of national energy security, understood as the ability to ensure stable energy supplies and to identify at an early stage any unusual phenomena that may indicate data errors, technical disruptions or system events. The research data consisted of publicly available ENTSO-E data on Poland's power system load for 2022-2024. The data were cleaned, normalised, and chronologically split into training, validation, and test sets. The model was trained to reconstruct typical weekly load profiles, and detection was based on the reconstruction error value. In the test phase, synthetic anomaly scenarios were used: positive spike, drop, flatline and drift. The results indicate that the model best identifies sudden drops in load, partially detects positive spikes, but reacts less effectively to slowly rising changes and flatline patterns. The results obtained confirm the usefulness of the reconstruction approach as a tool supporting power system monitoring, whilst acknowledging the need for operator validation and the supplementation of the model with additional contextual variables, such as weather, renewable energy generation and demand forecasts.

Keywords: energy security, power system, anomaly detection, LSTM Autoencoder, ENTSO-E, power load, artificial intelligence

Wstęp

Bezpieczeństwo państwa zależy obecnie w szczególnym stopniu od stabilnych dostaw energii (Sovacool, Mukherjee, 2011; Winzer, 2012). Jednym z elementów wspierających bezpieczeństwo energetyczne państwa jest systematyczna analiza zużycia energii, obciążenia systemu oraz detekcja anomalii jako potencjalnych sygnałów zagrożenia (Chandola i in., 2009; Pang i in., 2021). Obciążenie pokazuje, jakie jest zapotrzebowanie odbiorców na moc w analizowanym oknie czasowym, np. w danej godzinie (ENTSO-E, b.d.-a; Kardi i in., 2021). Nagły skok albo spadek może oznaczać błąd danych lub nietypowe zdarzenie systemowe (Karkhaneh, Ozgoli, 2022). Może też wskazywać anomalie obciążenia systemu elektroenergetycznego krajowego. Anomalia oznacza przebieg, który wyraźnie odbiega od zwykłego. Takie odchylenie może wskazywać na błąd danych albo zdarzenie. By pozyskać dane do analizy, zdecydowano się na ENTSO-E (European Network of Transmission System Operators for Electricity). Platforma ENTSO-E udostępnia publiczne dane o obciążeniu krajów (ENTSO-E b.d.-c). Dzięki temu badanie można odtworzyć wyłącznie na podstawie publicznie dostępnych i sprawdzonych danych (Wiese i in., 2019). Badanie sprawdza, czy prosty model AI może zostać użyty do wskazywania podejrzanych okien czasowych. LSTM Autoencoder to autoenkoder wykorzystujący sieć typu Long Short-Term Memory, uczący się reprezentacji typowych przebiegów obciążenia (Hochreiter, Schmidhuber, 1997; Sakurada, Yairi, 2014). Potem próbuje odtworzyć nowe okna z danych testowych. Gdy odtworzenie jest słabe, błąd modelu rośnie wyraźnie. Błąd rekonstrukcji pokazuje, jak źle model odtworzył okno. Duży błąd oznacza, że przebieg wygląda nietypowo dla modelu. Tak powstaje sygnał do dalszego sprawdzenia danych systemowych. Model nie zastępuje operatora, lecz wskazuje okna czasowe wymagające kontroli technicznej (Hochreiter, Schmidhuber, 1997; Pang i in., 2021).

Okno tygodniowe obejmuje rytm dnia oraz tygodnia systemu. To ważne, bo zużycie prądu zmienia się regularnie. Podział chronologiczny chroni badanie przed przeciekiem informacji czasowej. Celem badania była ocena, czy model LSTM Autoencoder może wskazywać anomalie w godzinowych danych obciążenia krajowego systemu elektroenergetycznego. Sprawdzono, czy błąd rekonstrukcji pozwala odróżnić okna z anomaliami syntetycznymi od okien typowych.

Materiał i metody

Dane pochodziły z publicznych zasobów ENTSO-E dla Polski (ENTSO-E, b.d.-d). Obejmowały trzy lata godzinowych wartości obciążenia systemu krajowego. Po oczyszczeniu zostało dwadzieścia sześć tysięcy trzysta cztery obserwacje. Trzy braki uzupełniono interpolacją, trzy duplikaty uśredniono przed analizą. w danych ENTSO-E Polska jako obszar elektroenergetyczny jest identyfikowana specjalnym kodem: EIC 10YPL-AREA-----S (ENTSO--E, b.d.-b). Zastosowano dane publiczne, ponieważ każdy może sprawdzić zastosowaną procedurę (Wiese i in., 2019). To ułatwia powtórzenie badania bez systemów operatora sieci. Każde okno miało tydzień, czyli sto sześćdziesiąt osiem godzin (Karkhaneh, Ozgoli 2022). Okno przesuwano co dobę, aby zmniejszyć obliczenia modelu. Najpierw dane przeskalowano tylko na części uczącej modelu. Potem tak samo przekształcono walidację oraz test modelu. To zmniejsza ryzyko podpowiadania modelowi przyszłych wyników danych. Autoenkoder uczył się odtwarzać zwykłe okna obciążenia systemu (Lin i in., 2024). Alarm powstawał wtedy, gdy błąd odtworzenia przekraczał próg. Próg ustalano na podstawie wyników części walidacyjnej danych. Próg percentylowy wybiera granicę z danych walidacyjnych modelu. Niższy próg daje więcej alarmów i większą czułość. Wyższy próg daje mniej alarmów i mniejszą czułość. Najważniejsze dane zestawiono w Tabeli 1. Tabela 2 pokazuje ustawienia użytego modelu w badaniu.

Tabela 1. Charakterystyka wykorzystanych danych

Parametr	Wartość
Źródło	ENTSO-E Power Statistics, Monthly Hourly Load Values
Powiązanie ze źródłem głównym	zestaw oparty na agregacjach Transparency Platform
Obszar	Poland / PL
Kod EIC	10YPL-AREA-----S
Okres	2022-01-01 00:00 UTC – 2024-12-31 23:00 UTC
Jednostka	MW
Liczba obserwacji po oczyszczeniu	26 304
Braki uzupełnione interpolacją	3
Duplikaty uśrednione	3
Podział train / validation / test	17520 / 4368 / 4416

Źródło: opracowanie własne na podstawie ENTSO-E, b.d.-b, b.d.-c, b.d.-d.

Tabela 2. Parametry procedury uczenia i detekcji

Parametr	Wartość
Model	LSTM Autoencoder
Długość okna	168 h
Krok okna	24 h
Liczba cech wejściowych	1
Warstwa kodera	LSTM, 8 jednostek ukrytych
Warstwa dekodera	LSTM, 8 jednostek ukrytych
Normalizacja	MinMax, dopasowanie tylko na zbiorze train
Funkcja straty	MAE
Optymalizator	Adam
Epoki	8
Wskaźnik detekcji	maksymalny błąd bezwzględny rekonstrukcji w oknie

Źródło: opracowanie własne.

Wyniki

Scenariusze testowe dodano sztucznie, aby znać położenie anomalii. Skok oznacza nagły wzrost wartości w krótkim czasie (Chandola i in., 2009). Spadek oznacza nagłe zmniejszenie obciążenia w badanym oknie. Dryf oznacza powolną zmianę poziomu obciążenia w czasie. Taki przebieg może być trudniejszy do wykrycia (Pang i in., 2021). Zmiana rozłożona w czasie często nie tworzy wysokiego błędu rekonstrukcji modelu. Model może uznać dryf za zmianę dopuszczalną. Dlatego jego wykrycie wymaga często dodatkowych cech albo niższego progu detekcji. Flatline oznacza okres bez widocznej zmiany obciążenia danych. Tabela 3 pokazuje rodzaj, czas oraz siłę zmian.

Tabela 3. Scenariusze anomalii syntetycznych

Scenariusz	Początek	Czas trwania	Modyfikacja
Skok dodatni	2024-09-10 08:00 UTC	6 h	+35 procent
Spadek	2024-10-22 18:00 UTC	12 h	-35 procent
Flatline	2024-11-15 00:00 UTC	24 h	stała wartość
Dryf	2024-12-03 00:00 UTC	24 h	od 0 do +25 procent

Źródło: opracowanie własne.

Precision oznacza odsetek alarmów, które naprawdę wskazały anomalię. Recall oznacza odsetek anomalii, które model faktycznie znalazł. F1 łączy oba wyniki w jedną ocenę jakości. Uczenie zakończono po ośmiu epokach pracy modelu testowego. Najniższa strata walidacyjna wyniosła około 0,170 w tej próbie. Próg główny nie dawał fałszywych alarmów w teście. Jednocześnie wykrył tylko część okien z anomaliami syntetycznymi. Najlepiej rozpoznano spadek obciążenia o trzydzieści pięć procent. Skok dodatni wykryto częściowo, a dryfu nie wykryto. Flatline także nie przekroczył przyjętego progu alarmowego modelu. Niższy próg zwiększył recall bez fałszywych alarmów testowych. Wyższy próg zmniejszył liczbę wykrytych anomalii w testach. Czwarta tabela pokazuje wyniki dla progów detekcji modelu. Piąta tabela pokazuje skuteczność dla typów anomalii testowych.

Tabela 4. Wyniki detekcji dla progów percentylowych

Próg	Wartość progu	Precision	Recall	F1	FP	FN
0.950	0.513685	1.000	0.621	0.766	0	11
0.990	0.545169	1.000	0.345	0.513	0	19
0.995	0.546137	1.000	0.345	0.513	0	19
0.999	0.548783	1.000	0.310	0.474	0	20

Źródło: opracowanie własne.

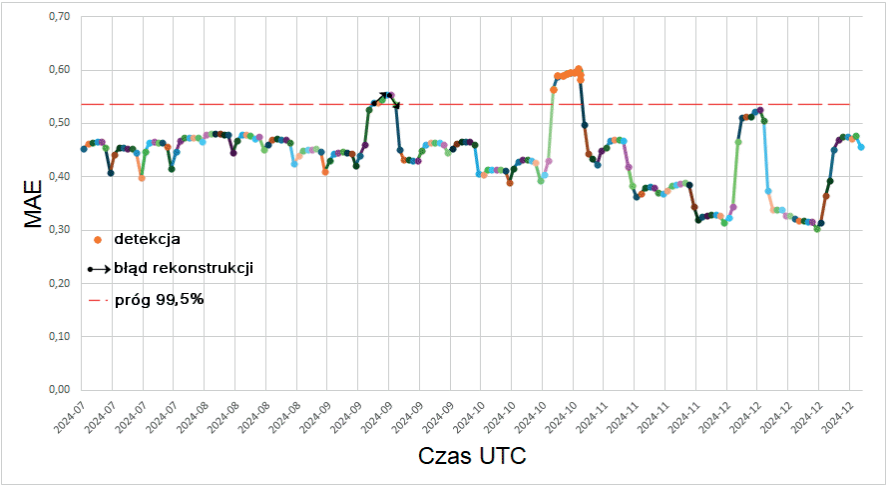
Niższy próg zwiększa czułość detektora anomalii. Próg 0,950 dał najwyższy recall bez fałszywych alarmów testowych w modelu. Wyższe progi ograniczały liczbę wykrytych przypadków. Porównanie pokazuje kompromis między ostrożnością alarmu a kompletnością detekcji anomalii testowych (Tabela 5).

Tabela 5. Wykrywalność według typu anomalii przy progu 0,995

Typ	Godziny	Okna dodatnie	Okna wykryte	Recall okien
skok_plus_35	6	7	3	0.429
spadek_minus_35	12	8	7	0.875
flatline_24h	24	7	0	0.000
dryf_plus_25	24	7	0	0.000

Źródło: opracowanie własne.

Najlepiej wykrywano spadek obciążenia systemu krajowego. Skok dodatni został wykryty częściowo, a dryf pozostał niewykryty w teście. Flatline nie przekroczył przyjętego progu alarmowego. Wyniki wskazują potrzebę dodatkowych cech dla wolniejszych zmian obciążenia systemu krajowego. Rysunek 1 pokazuje zmiany błędu rekonstrukcji w czasie. Próg pokazuje wartość, powyżej której model zgłasza potencjalną anomalię okna testowego danych. Największe piki błędu odpowiadają wykrytym zakłóceniom testowym. Brak przekroczenia progu oznacza, że dane nie uruchomiły alarmu detekcyjnego modelu automatycznie. Wykres ułatwia ocenę zachowania detektora w czasie. Pozwala też porównać reakcję modelu z położeniem wcześniej dodanych anomalii syntetycznych testowych.



Rysunek 1. Błąd rekonstrukcji i detekcje w zbiorze testowym

Źródło: opracowanie własne na podstawie ENTSO-E, b.d.-d.

Dyskusja

Wynik trzeba rozumieć jako sygnał wstępny, nie diagnozę. Dane godzinowe są zbyt ogólne, aby wskazać przyczynę (Kardi i in., 2021). Operator powinien sprawdzić alarm razem z innymi danymi. Sam alarm nie wystarcza do oceny zagrożenia energetycznego (Winzer, 2012). Model najlepiej reagował na szybkie zmiany wielkości obciążenia. Powolne zmiany mogły wyglądać dla niego zwyczajnie w danych. Dlatego dryf nie został wykryty

w tej próbie. Podobnie flatline nie przekroczył głównej granicy alarmowej modelu. Uzyskane wyniki potwierdzają użyteczność rekonstrukcji w monitoringu obciążenia systemu. Jednocześnie pokazują, że sama wartość błędu nie opisuje przyczyn zakłóceń w sieci. Model najlepiej reaguje na nagłe zmiany amplitudy sygnału obciążenia. Słabsza detekcja dryfu wskazuje na potrzebę uwzględnienia cech długookresowych szeregu czasowego w modelu. Flatline wymaga osobnej interpretacji, ponieważ nie zawsze zwiększa błąd. W praktyce podobny przebieg może oznaczać awarię pomiaru albo stabilny odczyt systemowy. Dlatego detekcja powinna być zawsze łączona z wiedzą operatorską. Dodatkowe zmienne mogłyby ograniczyć liczbę niejednoznacznych alarmów w ocenie systemu przez operatora. Szczególnie istotne są temperatura, generacja OZE oraz prognozy zapotrzebowania (ENTSO-E, b.d.-a; Shrestha i in., 2024). Takie dane pomagają odróżnić nietypowość techniczną od normalnej reakcji odbiorców energii elektrycznej. Wyniki należy traktować jako etap walidacji koncepcji badawczej modelu. Przed wdrożeniem potrzebne są testy na zdarzeniach potwierdzonych przez operatora systemu krajowego. Do dalszych badań warto dodać pogodę oraz produkcję OZE. Można także użyć prognozy zapotrzebowania na energię elektryczną. Lepsze dane pomogłyby odróżnić błąd od zdarzenia systemowego. Metoda wspiera monitoring, ale wymaga rozsądnej interpretacji eksperta. Bezpieczeństwo energetyczne dotyczy dostaw, danych oraz decyzji państwa. Właśnie dlatego wynik modelu powinien wspierać decyzję człowieka. Nie powinien samodzielnie przesądzać o stanie systemu krajowego.

Wnioski

LSTM Autoencoder może pomagać w prostym monitoringu obciążenia (Nam i in., 2020). Najpierw wskazuje miejsca, które warto sprawdzić dokładniej technicznie. Nie wyjaśnia jednak, dlaczego pojawiła się dana anomalia. W pilotażu najlepiej wykrywał spadki godzinowego obciążenia systemu. Dryf i flatline wymagają innych cech albo progów. Przed użyciem operacyjnym potrzebna jest walidacja operatorska metody. Najbezpieczniej traktować wynik jako listę spraw do kontroli. Model potwierdza przydatność rekonstrukcji w monitoringu obciążenia systemowego. Nie stanowi jednak samodzielnego narzędzia diagnozy pracy krajowej sieci elektroenergetycznej w praktyce. Największą skuteczność uzyskano dla gwałtownych

spadków obciążenia systemu. Słabsze wyniki dla dryfu pokazują ograniczenia prostej detekcji rekonstrukcyjnej w analizie operacyjnej. Próg alarmowy wymaga dostosowania do potrzeb operatora systemu. Zbyt niski próg może zwiększać liczbę zgłoszeń wymagających kontroli technicznej przez operatora. Zastosowanie operacyjne wymaga walidacji systemu na zdarzeniach rzeczywistych. Dalsze badania powinny uwzględnić pogodę, OZE oraz prognozy zapotrzebowania dla krajowego systemu. Metoda może wspierać priorytetyzację kontroli dużych zbiorów danych. Ostateczna decyzja powinna łączyć wynik modelu z oceną eksperta oraz kontekstem operatorskim.

Literatura

1. Chandola, V., Banerjee, A., Kumar, V. (2009). Anomaly detection: A survey. *ACM Computing Surveys, 41*(3), Article 15. https://doi.org/10.1145/1541880.1541882
2. ENTSO-E. (b.d.-a). *Actual total load & day-ahead total load forecast*. Pobrane z: 18 maja 2026 https://transparencyplatform.zendesk.com/hc/en-us/articles/15885757679124-Actual-Total-Load-Day-ahead-Total--Load-Forecast-6-1-A-B (dostęp: 18.05.2026).
3. ENTSO-E. (b.d.-b). *EIC approved codes*. Pobrane z: https://www.entsoe.eu/data/energy-identification-codes-eic/eic-approved-codes/ (dostęp: 18.05.2026).
4. ENTSO-E. (b.d.-c). *Electricity market transparency*. Pobrane z: https://www.entsoe.eu/data/transparency-platform/ (dostęp: 18.05.2026).
5. ENTSO-E. (b.d.-d). *Monthly hourly load values. Power statistics*. Pobrane z: https://www.entsoe.eu/publications/data/power-stats/ (dostęp: 18.05.2026).
6. Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural Computation, 9*(8), 1735-1780. https://doi.org/10.1162/neco.1997.9.8.1735
7. Kardi, M., AlSkaif, T., Tekinerdogan, B., Catalão, J. P. S. (2021). *Anomaly detection in electricity consumption data using deep learning*. 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe. https://doi.org/10.1109/EEEIC/ICPSEurope51590.2021.9584650

8. Karkhaneh, M., Ozgoli, S. (2022). Anomalous load profile detection in power systems using wavelet transform and robust regression. *Advanced Engineering Informatics, 53*, Article 101639. https://doi.org/10.1016/j.aei.2022.101639
9. Lin, R., Chen, S., He, Z., Wu, B., Zou, H., Zhao, X., Li, Q. (2024). Electricity behavior modeling and anomaly detection services based on a deep variational autoencoder network. *Energies, 17*(16), Article 3904. https://doi.org/10.3390/en17163904
10. Nam, G., Jeong, H., Park, P. (2020). *An anomaly detection scheme based on LSTM autoencoder for energy management.* International Conference on Information and Communication Technology Convergence. https://doi.org/10.1109/ICTC49870.2020.9289226
11. Pang, G., Shen, C., Cao, L., van den Hengel, A. (2021). Deep learning for anomaly detection: A review. *ACM Computing Surveys, 54*(2), Article 38. https://doi.org/10.1145/3439950
12. Sakurada, M., Yairi, T. (2014). *Anomaly detection using autoencoders with nonlinear dimensionality reduction*. Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis. https://doi.org/10.1145/2689746.2689747
13. Shrestha, R., Mohammadi, M., Sinaei, S., Salcines, A., Pampliega, D., Clemente, R., Sanz, A., Nowroozi, E., Lindgren, A. (2024). Anomaly detection based on LSTM and autoencoders using federated learning in smart electric grid. *Journal of Parallel and Distributed Computing, 193*, Article 104951. https://doi.org/10.1016/j.jpdc.2024.104951
14. Sovacool, B. K., Mukherjee, I. (2011). Conceptualizing and measuring energy security: A synthesized approach. *Energy, 36*(8), 5343-5355. https://doi.org/10.1016/j.energy.2011.06.043
15. Wiese, F., Schlecht, I., Bunke, W.-D., Gerbaulet, C., Hirth, L., Jahn, M., Kunz, F., Lorenz, C., Mühlenpfordt, J., Reimann, J., Schill, W.-P. (2019). Open Power System Data – Frictionless data for electricity system modelling. *Applied Energy, 236*, 401-409. https://doi.org/10.1016/j.apenergy.2018.11.097
16. Winzer, C. (2012). Conceptualizing energy security. *Energy Policy, 46*, 36-48. https://doi.org/10.1016/j.enpol.2012.02.067