

DOI 10.21008/j.1897-0737.2021.106.0005

Robert SMYK\*, Paweł KOWALSKI\*

## **PROGNOZOWANIE ZUŻYCIA ENERGII ELEKTRYCZNEJ W TRAKCIE PANDEMII PRZY UŻYCIU MODELI SZEREGÓW CZASOWYCH**

W artykule przeanalizowano zmiany zapotrzebowania na energię elektryczną w Polsce w trakcie trwania okresów zamrożenia niektórych sektorów gospodarki. Wykonano analizy statystyczne historycznych danych zużycia energii. Zaproponowano również model prognozowania zapotrzebowania na energię elektryczną i wykonano jego weryfikację wykorzystując dane historyczne i bieżące podczas trwania pandemii. Zaproponowano modelowanie przy użyciu szeregów czasowych. Zaprezentowano szczegółowe parametry modeli, także omówiono metodykę ich strojenia.

**SŁOWA KLUCZOWE:** wytwarzanie energii elektrycznej, polityka energetyczna, wpływ na środowisko, energia, bazy danych, covid-19, mobilność, środowisko.

### **1. ANALIZA TRENDÓW ZAPOTRZEBOWANIA NA ENERGIĘ ELEKTRYCZNĄ**


Typowym zadaniem wykonywanym w fazie wstępnej opracowania modeli prognozujących trendy aktualne lub przyszłe jest analiza danych historycznych. W niniejszym opracowaniu wykorzystano zbiory danych z bazy ENTSO [1]. Baza ta dostarcza danych godzinowych zużycia energii elektrycznej dla wybranych krajów, co powszechnie wykorzystywane jest przez różne instytucje do prognozowania zależności występujących na rynku energii. Ze względu na usystematyzowanie niniejszych danych w sensie wartości sumarycznego zużycie energii w danej jednostce czasu, zbiory te mogą być poddawane metodom analizy wykorzystywanym w obróbce numerycznej tzw. szeregów czasowych [4].

W początkowej fazie eksperymentów wykonano analizę graficzną danych w celu określenia występowania prawidłowości. Pozwoliło to między innymi na oszacowanie sezonowości oraz trendu (rys. 1). Cechy te wynikają głównie z warunków klimatycznych w krajach bałtyckich, gdzie jesienią, zimą i wiosną obserwuje się wykładniczy trend zapotrzebowania na energię elektryczną. W Polsce od marca do czerwca typowo w szczycie sezonu obserwuje się trend spadkowy. Przedstawione dane zawierają próbki miesięczne. Na rys. 2 zawarto ten sam zbiór,


---

\* Państwowa Wyższa Szkoła Zawodowa w Elblągu.

lecz próbkowany z odstępami dziennymi. W okresie czerwiec-sierpień zużycie energii wzrasta z nieznaczną tendencją, następnie ostry trend wzrostowy występuje we wrześniu-lutym z maksymalną wartością w miesiącach grudzień-styczeń.




Rys. 1. Miesięczne rzeczywiste zapotrzebowanie na energię w Polsce, zestawienie roczne godzinowe próbkowane godzinowo uśrednione w okresach miesięcznych (na osi 0 – styczeń, 11 – grudzień)




Rys. 2. Dzielne rzeczywiste zapotrzebowanie na energię, próbkowane godzinowo uśrednione w okresach dziennych

Analiza łącznego zużycia energii (rys. 3) na przełomie blisko 30 lat i zużycia rok-do-roku z ostatnich 20 lat (rys. 4) pokazuje, że w krajach wysoko rozwiniętych, gdzie przyrost naturalny nie jest szybki, obserwuje się tendencję spadkową zapotrzebowania na energię elektryczną. Tendencja wzrostowa odpowiada wzrostowi zużycia energii rok do roku, a trend spadkowy obrazuje spadek zużycia energii w porównaniu do roku poprzedniego. Jest to podyktowane podjęciem wszelkich działań w tych krajach w celu poprawy efektywności gospodarowania energią. Jednak ogólny globalny trend zapotrzebowania na energię nie ma tendencji malejącej. Jak widać z analizy danych, większość krajów bałtyckich włączając Polskę, znajduje się obecnie w okresie malejącego zużycia energii elektrycznej.




Rys. 3. Zużycie energii elektrycznej na przestrzeni ostatnich 30 lat [19]



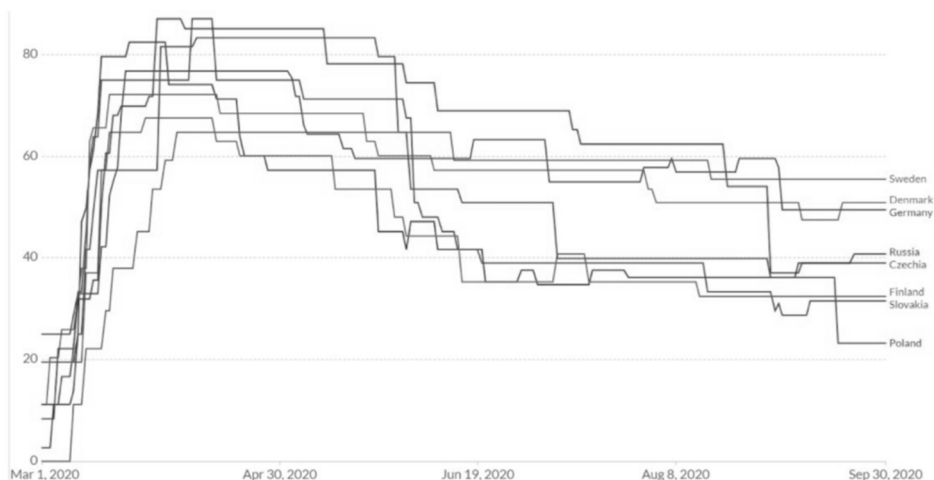
Rys. 4. Zużycie energii elektrycznej rok do roku na przestrzeni ostatnich 20 lat [20]

Porównując bezpośrednio trendy w popycie na energię elektryczną np. w roku 2019 przed Covid-19 i w roku 2020, można zaobserwować zakłócenia w sezonowości oraz typowym rocznym trendzie. Te odchylenia wyraźnie korelują z wartościami tzw. indeksu rygorystyczności zilustrowanego na rys. 5 i rys. 6. Indeks rygorystyczności jest miarą opracowaną przez Uniwersytet Blavatnik School of Government of Oxford [2]. Funkcja indeksu rygorystyczności stanowi miarę określającą stopień ograniczeń wprowadzonych w trakcie nasilenia zachorowań podczas pandemii w danym kraju. Wartości współczynnika są dostępne na rządowych stronach internetowych lub w bazie [2]. Indeks rygorystyczności składa się z dziewięciu wskaźników, tj.: zamknięcie szkół, zamknięcie miejsc pracy, odwołanie wydarzeń publicznych, ograniczenia wielkości zgromadzeń publicznych, ograniczenia w transporcie publicznym, wymagania dotyczące pobytu w domu, ograniczenia w przemieszczaniu się wewnątrz kraju, ograniczenia w przemieszczaniu się między państwami, publiczne kampanie informacyjne.

W Polsce podczas pandemii w 2020 r. miały miejsce dwa znaczące okresy blokady rządowej, tj. marzec-maj 2020 r. i listopad-grudzień 2020 i jeden dodatkowy okres w miesiącach styczeń-luty 2021. Później w 2021 zastosowano blokadę z mniejszymi ograniczeniami, wprowadzoną na przełomie marca-kwietnia 2021. Dane dotyczące okresów zamrażania gospodarki z punktu widzenia opracowania modelu wprowadzają stały czynnik reprezentujący zmniejszenie popytu na dobra konsumpcyjne, w tym zużycie energii elektrycznej. Z drugiej strony w krajach takich jak Polska nie wprowadzono całkowitego zamrożenia gospodarki, a przemysł lokalny jednak funkcjonował.



Rys. 5. Indeks rygorystyczności od 21.01.2020 do 22.05.2021 [2]



Rys. 6. Indeks rygorystyczności od 01.03.2020 do 30.08.2020

## 2. MODELE SZEREGÓW CZASOWYCH

Przedstawione w poprzednim punkcie zbiory danych reprezentujące zużycie energii elektrycznej można traktować jak szeregi czasowe, w których próbki danych rozłożone są względem siebie w równych interwałach. Prognozowanie szeregów czasowych polega na opracowaniu zastępczego modelu matematycznego, umożliwiającego określenie bieżących lub przyszłych wartości szeregu. Model taki powinien uwzględnić pewne cechy wybiórcze szeregu czasowego, jak np. sezonowość czy trend.

Jednym z wyjściowych modeli stosowanych przy prognozowaniu szeregów czasowych są autoregresyjne modele ze średnią kroczącą ARMA (Auto Regression – AR, Moving Average, MA) [4]. Przyjmuje się, że  $\{x_t, t \in Z\}$  jest autoregresyjnym procesem ze średnią kroczącą, rzędu  $(p, q)$  oznaczonym jako  $x_t \sim ARMA(p, q)$ , jeżeli

$$x_t - \phi_1 x_{t-1} - \dots - \phi_p x_{t-p} = u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q} \text{ dla każdego } t \in Z, (1)$$

gdzie  $u_t \sim WN(0, \sigma_u^2)$  reprezentuje szum biały ze średnią 0 oraz wariancją  $\sigma_u^2$ , oraz  $\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q$  są stałymi współczynnikami o liczbie  $p + q$  oraz zachodzi brak wspólnych czynników między wielomianami

$$\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p (2)$$

oraz

$$\theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q. \quad (3)$$

Przyjmuje się również, że dla  $q = 0$  mamy do czynienia z procesem autoregresyjnym rzędu  $p$ , oznaczonym  $x_t \sim AR(p)$

$$x_t - \phi_1 x_{t-1} - \dots - \phi_p x_{t-p} = u_t \text{ dla każdego } t \in Z. \quad (4)$$

Podobnie, dla  $p = 0$  otrzymuje się proces rzędu  $q$  ze zmienną kroczącą oznaczony jako  $x_t \sim MA(q)$

$$x_t = u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q} \text{ dla każdego } t \in Z. \quad (5)$$

Modele ARMA mają zastosowanie dla procesów stacjonarnych, co zachodzi gdy

$$\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0 \text{ dla } |z| = 1. \quad (6)$$

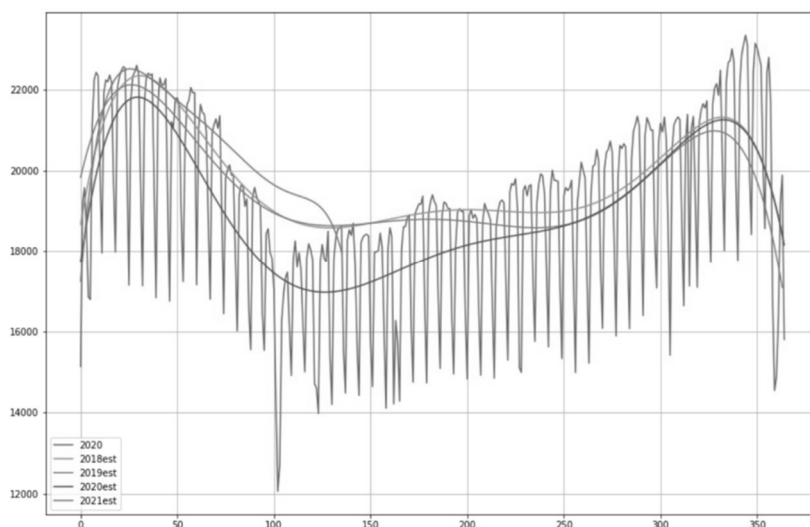
W praktyce przyjmuje się, że proces jest stacjonarny, kiedy jego średnia, wariancja i autokorelacja nie zmieniają się w czasie. W przypadku szeregów czasowych niestacjonarnych istnieje możliwość zastosowania modeli ARMA po sprowadzeniu ich do stacjonarności. Szczegółowe rozważania dotyczące możliwości wykorzystania modelowania typu ARMA zostały podane w następnym punkcie.

### 3. PROPONOWANE PODEJŚCIE DO MODELOWANIA ZUŻYCIA ENERGII

Celem eksperymentów było opracowanie modelu pozwalającego na oszacowanie zapotrzebowania na energię elektryczną w okresie trwania obostrzeń związanych z pandemią. Jak pokazują dane zestawione dla lat 2019 i 2020 dotyczące sumarycznego zapotrzebowania na energię elektryczną. Dla Polski w poszczególnych porach roku (kwartałach) zużycie energii wykazuje ogólną tendencję spadkową, porównując dane rok do roku (rys. 7).

Z drugiej strony aktualne dane za 2021 r. pokazują trend wzrostowy, który może być wywołany gwałtownym wybudzaniem się gospodarki po pandemicznych ograniczeniach. Z analizy danych sumarycznych wynika, że wprowadzenie rządowych ograniczeń w Polsce miało pewien wpływ na zużycie energii ale nie były to gwałtowne spadki zużycia energii elektrycznej (tab. 1).

Dość powszechnym współcześnie podejściem jest wykorzystanie do modelowania czy prognozowania algorytmów sztucznej inteligencji, w szczególności sieci neuronowych. Sprawdzają się one, jeśli mamy wiele zestawów treningowych i niestety tym samym są mniej efektywne, gdy występuje brak odpowiednich zestawów treningowych. Z drugiej strony znane są modele statystyczne, które wykazują dobre właściwości, szczególnie w przypadkach ubogich zestawów danych treningowych.



Rys. 7. Zestawienie danych rzeczywistych z 2020 roku i trendów obliczonych dla lat 2018, 2019 i 2020

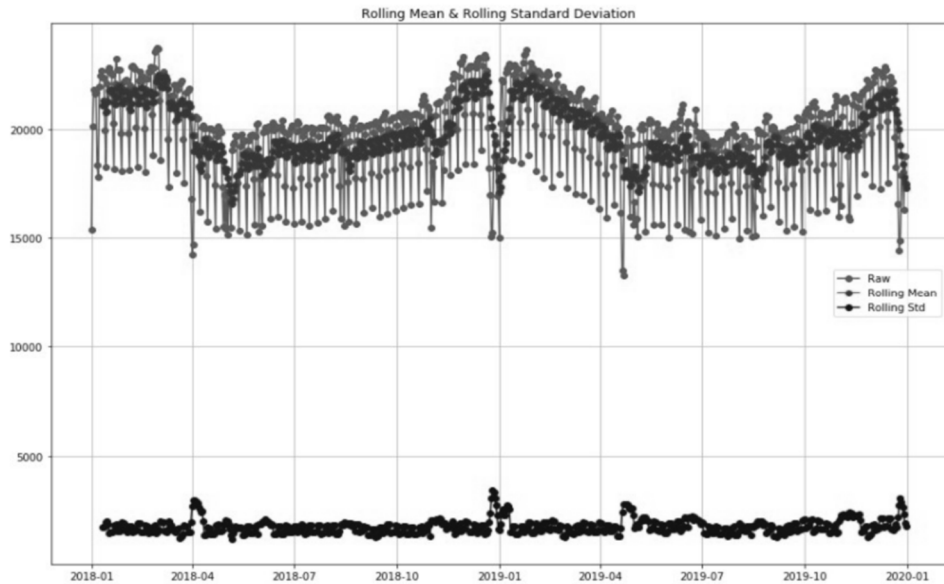
Tabela 1. Statystyki sumaryczne zużycia energii elektrycznej w Polsce dla danych próbkowanych godzinowo

Rok	2018	2019	2020	2021 (do maja)
min	14233	13260	12062	13728
max	23725	23637	23350	24573
średnie	19817	19605	19053	20612


Wspomniana elastyczność modeli statystycznych, skłoniła autorów do wykorzystania tych modeli do analizy i modelowania danych o zużyciu energii elektrycznej.

W początkowym etapie analiz w celu określania właściwości modeli zweryfikowano cechy zestawu danych uczących. Przyjęto zbiór danych obejmujących okres 2018-2019 (rys. 8). Przeprowadzając analizę statystyczną tych danych, finalnie zaproponowano model autoregresyjny typu Seasonal Autoregressive Integrated Moving Average (SARIMA) [3]. Model ten jest rozszerzeniem popularnego modelu ARIMA [3] z uwzględnieniem sezonowości danych. Oba wymienione modele należą do rodziny autoregresyjnych modeli statystycznych typu ARMA, którego podstawowe właściwości zaprezentowano w punkcie 2. W omawianym przypadku użycia tych modeli, część AR modelu w odniesieniu do danych historycznych zużycia energii generuje trend przyszłego zapotrzebowania na przyjęty okres (np. godzinowy, dzienny, miesięczny) bez aktualizacji obserwacji za ten okres. Drugi człon MA modelu generuje przyszły trend z uśrednioną aktualizacją o nowe obserwacje w kolejnych krokach obliczenio-

wych. Model ARMA posiada następujące parametry:  $p$  – liczba składników w części autoregresyjnej,  $q$  – liczba czynników modelujących błędy prognozy w równaniu predykcji. Wartości  $p$  i  $q$  uznaje się za rząd modelu ARMA. Przy dobieraniu tych parametrów stosuje się prosty test statystyczny polegający na graficznym wyznaczeniu funkcji autokorelacji (ACF) i funkcji częściowej autokorelacji (PACF). Wolno zanikający przebieg ACF oznacza niestacjonarność danych, co ilustrują rys. 9a i rys. 9b. Dalej ACF i PACF stosuje się do wyznaczenia odpowiednio wartości  $q$  oraz  $p$ .



Rys. 8. Zapotrzebowanie na energię elektryczną w latach 2019-2020 (dane surowe, średnia ważona i odchylenie standardowe)




Rys. 9a ACF dla zbioru danych z lat 2018-2019  
Rys. 9b PACF dla zbioru danych z lat 2018-2019



Wykorzystanie modeli ARMA ma ograniczenie dla zbiorów danych stacjonarnych. W przypadku, gdy test na niestacjonarność okaże się pozytywny można dla próbek takiego zbioru danych obliczyć różnicę w miejscu między sąsiednimi próbkami, co w praktyce odpowiada obliczaniu pierwszej pochodnej. Dodatkowo obliczenie pierwszej pochodnej pozwala w większości przypadków na wyeliminowanie sezonowości, co pokazano na rys. 10.

W praktyce spotykane są typowo dwa podejścia doboru modelu, jedno bazuje na wykorzystaniu modelowania ARMA poprzedzonego wstępną obróbką danych polegającą na eliminacji niestacjonarności i sezonowości. W tym przypadku dąży się do uzyskania modelu ARMA, co wymaga stosowania często wielu etapów obróbki danych uczących dla modelu. Inne znane podejście to użycie modeli bazującymi na ARMA, ale z wbudowanymi mechanizmami eliminowania wspomnianych cech wejściowego zbioru danych. W tym przypadku modele stroi się na surowych danych cechujących się trendem i sezonowością oraz niestacjonarnością.



Rys. 10. Dane zapotrzebowania na energię elektryczną (2018-2019) poddane dekompozycji eliminującej niestacjonarność sezonowość poprzez obliczenie pierwszej pochodnej

Dla zbioru danych cechującego się niestacjonarnością można wykorzystać model typu  $ARIMA(p,d,q)$ , który zawiera składnik  $d$  określający stopień pochodnej, wymagany do osiągnięcia stacjonarności dla danego zbioru danych. W wielu przypadkach już obliczenie pierwszej pochodnej doprowadza do stacjonarności. Stąd też typowym podejściem jest modelowanie ARIMA z warto-

ścią współczynnika  $d = 1$ , a w najgorszym przypadku  $d = 2$ . W przypadku zbioru cechującego się dodatkowo sezonowością istnieje możliwość wykorzystania modelu typu SARIMA.

#### 4. REZULTATY

Jednym ze sposobów strojenia modeli bazujących na analizie szeregów czasowych jest podawanie zbioru danych wejściowych uczących przy z góry założonych parametrach modelu  $(p, d, q)$ . Dla danego modelu wyznacza się tzw. współczynnik AIC (Akaike information criterion) [5]. Dąży się do tego, aby wartość AIC była jak najmniejsza. Współczynnik ten estymuje relatywną jakość modelu statystycznego dla konkretnej serii danych. Zatem wyliczając go dla zbioru danych wejściowych i przyjętej konfiguracji modelu AIC jesteśmy w stanie określić jaka konfiguracja parametrów modelu jest najbardziej odpowiednia. Tego typu podejście jest używane przy procedurze automatyzacji doboru parametrów modeli ARMA. W niniejszym opracowaniu zastosowano również omawiany pomysł.

W wyniku przeprowadzonych eksperymentów uzyskano parametry sezonowego modelu SARIMA( $p, d, q$ )x( $P, D, Q$ ), gdzie  $p, d, q$  definiują część modelu ARMA bez sezonowości a parametry  $P, D, Q$  z uwzględnieniem sezonowości. Zależność określająca ten model jest następująca:

$$\Phi_p(L)\Phi_p(L^S)\Delta^d\Delta^D_S y_t = A(t) + \Theta_q(L)\Theta_q(L^S)\tilde{\eta}_t \quad (7)$$

gdzie  $\Phi_p(L)$  reprezentuje wielomian modelujący nie sezonową część autoregresyjną (AR),  $\Phi_p(L^S)$  wielomian modelujący sezonową część AR, składnik  $\Delta^d\Delta^D_S$  reprezentuje odpowiednio niesezonowy i sezonowy szereg czasowy ( $d$  i  $D$  to stopień pochodnej),  $A(t)$  wielomian modelujący trend,  $\Theta_q(L)\Theta_q(L^S)$  składniki MA uwzględniające odpowiednio brak sezonowości i jej występowanie.

Rysunki 11-13 ilustrują szczegółowe parametry uzyskanych modeli typu SARIMA. Strojenie modeli wykonano przy użyciu trzech zbiorów danych: zbioru danych uczących reprezentujących zapotrzebowanie na energię elektryczną w Polsce w latach 2018-2019 (rys. 8) oznaczonym Z1819, zbioru reprezentującym zapotrzebowanie w roku 2019 oznaczonym Z19 i pełnym zbiorze danych reprezentującym zapotrzebowanie w roku 2020 oznaczonym Z20. Zbiór Z20 został użyty w celu uzyskania modelu idealnego, służącego do porównania. Dla zbioru Z1819 uzyskano model SARIMA(5,1,0)x(5,1,0) (rys. 11). Mając na uwadze zależność (1), uzyskaliśmy tu następujący model

$$(1 - \Phi_L - \Phi_2 L^2 - \dots - \Phi_5 L^5) \left( 1 - \Phi_7 L^7 - \Phi_{14} L^{14} - \dots - \Phi_{35} L^{35} \right) \Delta^1 \Delta^1_7 = c + \tilde{\eta}_t$$

przyjmując, że A(t) jest stałe c. Poszczególne składniki  $L^i, i = 7, 14, 21, 28, 35$  na rys. 11 są oznaczone jako ar.S.L7, ..., ar.S.L35 (składnik sezonowy modelu). Analogicznie można określić składnik niesezonowy modelu. Model strojony przy użyciu zbioru Z1819 oznaczono M1819. Podobną konwencję oznaczeń wprowadzono dla pozostałych modeli.

SARIMAX Results						
Dep. Variable:		y		No. Observations:		729
Model:		SARIMAX(5, 1, 0)x(5, 1, 0, 7)		Log Likelihood		-5963.851
Date:		Tue, 25 May 2021		AIC		11949.702
Time:		13:17:19		BIC		12000.089
Sample:		0		HQIC		11969.153
Covariance Type:		opg				
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	-0.1387	0.017	-7.968	0.000	-0.173	-0.105
ar.L2	-0.1803	0.032	-5.620	0.000	-0.243	-0.117
ar.L3	-0.1749	0.036	-4.813	0.000	-0.246	-0.104
ar.L4	-0.1353	0.039	-3.450	0.001	-0.212	-0.058
ar.L5	-0.0975	0.039	-2.530	0.011	-0.173	-0.022
ar.S.L7	-0.7761	0.034	-22.651	0.000	-0.843	-0.709
ar.S.L14	-0.6427	0.047	-13.558	0.000	-0.736	-0.550
ar.S.L21	-0.4643	0.052	-8.966	0.000	-0.566	-0.363
ar.S.L28	-0.2679	0.050	-5.374	0.000	-0.366	-0.170
ar.S.L35	-0.1277	0.032	-3.982	0.000	-0.191	-0.065
sigma2	8.759e+05	1.81e+04	48.401	0.000	8.4e+05	9.11e+05
Ljung-Box (L1) (Q):		0.01	Jarque-Bera (JB):		3921.63	
Prob(Q):		0.93	Prob(JB):		0.00	
Heteroskedasticity (H):		1.22	Skew:		-1.50	
Prob(H) (two-sided):		0.12	Kurtosis:		14.03	

Rys. 11. Parametry modelu regresyjnego SARIMA strojonego na danych zużycia energii w latach 2018-2019

SARIMAX Results						
Dep. Variable:		y		No. Observations:		364
Model:		SARIMAX(1, 1, 2)x(5, 1, [1], 7)		Log Likelihood		-2958.234
Date:		Tue, 25 May 2021		AIC		5936.467
Time:		13:12:32		BIC		5975.216
Sample:		0		HQIC		5951.881
Covariance Type:		opg				
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	0.9719	0.477	2.038	0.042	0.037	1.907
ma.L1	-1.0006	0.485	-2.062	0.039	-1.952	-0.049
ma.L2	0.0304	0.027	1.131	0.258	-0.022	0.083
ar.S.L7	-0.0250	0.067	-0.372	0.710	-0.157	0.107
ar.S.L14	-0.1234	0.066	-1.877	0.061	-0.252	0.005
ar.S.L21	-0.0822	0.069	-1.192	0.233	-0.217	0.053
ar.S.L28	-0.0757	0.072	-1.045	0.296	-0.218	0.066
ar.S.L35	-0.0615	0.079	-0.778	0.437	-0.216	0.093
ma.S.L7	-0.8716	0.059	-14.701	0.000	-0.988	-0.755
sigma2	9.014e+05	3.02e+04	29.804	0.000	8.42e+05	9.61e+05
Ljung-Box (L1) (Q):		1.93	Jarque-Bera (JB):		2108.61	
Prob(Q):		0.17	Prob(JB):		0.00	
Heteroskedasticity (H):		1.17	Skew:		-0.98	
Prob(H) (two-sided):		0.39	Kurtosis:		14.76	

Rys. 12. Parametry modelu regresyjnego SARIMA strojonego na danych zużycia energii w roku 2019

```

SARIMAX Results
=====
Dep. Variable:          y          No. Observations:      365
Model:                SARIMAX(2, 1, 1)x(0, 1, [1, 2], 7)      Log Likelihood         -2925.062
Date:                 Tue, 25 May 2021                        AIC                    5862.124
Time:                 13:08:16                                BIC                    5885.391
Sample:               0                                       HQIC                   5871.378
                    - 365
Covariance Type:      opg
=====
              coef    std err          z      P>|z|      [0.025    0.975]
-----
ar.L1          0.3869     0.129      2.989     0.003     0.133     0.641
ar.L2         -0.1500     0.045     -3.300     0.001    -0.239    -0.061
ma.L1         -0.5100     0.129     -3.956     0.000    -0.763    -0.257
ma.S.L7       -0.7334     0.045    -16.221     0.000    -0.822    -0.645
ma.S.L14      -0.1838     0.043     -4.315     0.000    -0.267    -0.100
sigma2        7.086e+05    2.31e+04    30.648     0.000    6.63e+05    7.54e+05
=====
Ljung-Box (L1) (Q):          0.38   Jarque-Bera (JB):          1095.07
Prob(Q):                    0.54   Prob(JB):                  0.00
Heteroskedasticity (H):     0.71   Skew:                      -1.17
Prob(H) (two-sided):        0.06   Kurtosis:                  11.26
=====


```

Rys. 13. Parametry modelu regresyjnego SARIMA strojonego na danych zużycia energii w roku 2020


Na rys. 14 pokazano przykład wykorzystania modelu M19 dla obliczenia prognozy zużycia energii elektrycznej w okresie 15.03-29.03.2020r. Fragment danych treningowych z roku 2019 zilustrowano na rys. 15. Dla uzyskanych modeli przeprowadzono również weryfikację wyznaczając dla wyjścia modelu i danych rzeczywistych średni procentowy błąd kwadratowy (MAPE), średni błąd bezwzględny (MAE), średni błąd procentowy (MPE), korelację między wartością rzeczywistą a modelowaną (CERR) oraz błąd minimum-maksimum (MINMAX), co zawarto w tab. 2. Średni błąd kwadratowy nie przekracza 2%, co daje dość wysoką dokładność modeli.

Tabela 2. Statystyki weryfikacji modeli; porównywano wyjście każdego modelu z rzeczywistymi próbkami zużycia energii w okresie 15-29.03.2020 r.

	M19	M1819	M20
MAPE	0,01990	0,020	0,0190
MAE	358,40000	354,450	349,4000
MPE	0,00094	0,001	0,0011
CERR	0,95700	0,970	0,9680
MINMAX	0,01950	0,020	0,0190



Rys. 14. Przykład rzeczywistego i prognozowanego zapotrzebowania na energię elektryczną w Polsce na początku okresu ograniczeń rządowych (15 marca 2020 do 29 marca 2020)



Rys. 15. Fragment danych treningowych z 2019 roku za okres od 15.03.2020 do 30.03.2020

## PODSUMOWANIE

W artykule zawarto analizę wpływu czynników związanych z pandemią Covid-19 na zużycie energii elektrycznej. W ramach opracowania podjęto się próby wykazania, że wykorzystując do strojenia modeli dane historyczne sumarycznego zużycia energii elektrycznej z przed roku lub dwóch lat przed pandemią możliwe jest uzyskanie satysfakcjonującego modelu. Skupiono się na modelach z rodziny ARMA. Z wykorzystaniem uzyskanego modelu możliwe jest prognozowanie sumarycznego zużycia energii z błędem średnio kwadratowym na poziomie 2%.

## LITERATURA

- [1] ENTSO-E, E.E., Available online: <https://transparency.entsoe.eu> (dostęp na dzień 30.05.2021 r.).
- [2] Hale, T.; Angrist, N.; Goldszmidt, R., Kira, B.; Petherick, A.; Phillips, T.; Webster, S.; Cameron-Blake, E.; Hallas, L.; Majumdar, S.; others. A global panel database of pandemic policies (Oxford COVID-19 Government Response Tracker). *Nature Human Behaviour* 2021, 5, 529–538.
- [3] Vagropoulos, S.I.; Chouliaras, G.; Kardakos, E.G., Simoglou, C. K., Bakirtzis, A.G. Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting. 2016 IEEE International Energy Conference (ENERGYCON). IEEE, 2016, pp. 1–6.
- [4] Box, G.E.; Jenkins, G.M.; Reinsel, G.C.: *Ljung, G.M., Time series analysis: forecasting and control*; John Wiley & Sons, 2015.
- [5] McElreath, R. *Statistical rethinking, A Bayesian course with examples in R and Stan*; Chapman and Hall/CRC, 2018; p. 189.

## FORECASTING ELECTRICITY CONSUMPTION DURING A PANDEMIC USING TIME SERIES MODELS

The article analyzes the impact of the Covid-19 pandemic on changes in electricity demand in Poland. Statistical analyzes of historical energy consumption data were performed. A model for forecasting electricity demand was also proposed and it was verified using historical and current data during the pandemic. Modeling using a time series has been proposed. The detailed parameters of the models were presented, as well as the methodology of their tuning.

*(Received: 06.08.2021, revised: 26.10.2021)*