

ZASTOSOWANIE TEORII SZARYCH SYSTEMÓW DO PROGNOZY POZYSKIWANIA I ZUŻYCIA ENERGII SŁONECZNEJ W POLSCE

APPLICATION OF THE GREY SYSTEM THEORY FOR A FORECAST OF THE SOLAR ENERGY USE IN POLAND

J. Janiszewski

Politechnika Poznańska, Instytut Elektrotechniki i Elektroniki Przemysłowej, Poznań, Polska

STRESZCZENIE

W publikacji poruszono zagadnienia dotyczące wykorzystania metody opartej na teorii szarych systemów (GST ang. Grey system theory) do modelowania i prognozowania pozyskiwania oraz zużycia energii słonecznej. Opracowano prognozy na bazie modelu szarych systemów ze względu na rosnące zapotrzebowanie wykorzystywania odnawialnych źródeł energii, prognozy mają na celu determinację inwestycji dążących do ekologicznego pozyskiwania energii. Omówiono teorię szarych systemów a w szczególności modelu typu GM(1,1). Do badań wykorzystano dane statystyczne dotyczące Polski opublikowane przez Główny Urząd Statystyczny. Efektem badań są wyniki symulacji całkowitego pozyskania jak i zużycia energii słonecznej w Polsce.

ABSTRACT

In the publication addressed issues concerning the use of the method based on the grey theory (GST. Grey system theory) for modeling and prediction for the acquisition and consumption of solar energy. Discuss the theory of gray systems and, in particular, model GM (1,1). The test uses the Polish statistics published by the Central Statistical Office. The result of the study are the simulation results of total acquisition and usage of solar energy in Poland.

WSTĘP

Energia słoneczna zapewnia wysoki poziom bezpieczeństwa energetycznego ponieważ dostęp do źródła energii jest nieograniczony. Jako konsument, jesteśmy niezależni od dostawców energii. Dzięki produkcji energii słonecznej na potrzeby własne konsumenta unika się takich zagrożeń jak wzrost kosztów czy ograniczeń dostaw energii. Korzystając z odnawialnych źródeł energii, chronimy nasz klimat. Rosnąca popularność jej zastosowań w domach mieszkalnych znacząco przyczynia się do oszczędności wynikających z pozyskania energii elektrycznej z OZE. W zakresie OZE energia słoneczna jest podstawowym źródłem przemiany energetycznej w prąd, obok energii wiatrowej, a jej masowe użytkowanie nie spowoduje wzrostu średniej temperatury.

Do zalet elektrowni słonecznych niewątpliwie można zaliczyć:

- możliwość korzystania z odnawialnego źródła energii;
- niezawodność ogniw fotowoltaicznych;
- umiarkowane koszty eksploatacji;
- elektrownie słoneczne nie działają negatywnie na środowisko naturalnie, nie emitują żadnych gazów cieplarnianych, ani odpadów po wyeksploatowaniu ogniwa utylizuje się ołów i kadm;
- sprawdzają się w miejscach trudno dostępnych.

Modelowane w pracy zużycie końcowe (finalne) dotyczy nośników energii wykorzystywanych przez odbiorców (sektor usług, przemysł, gospodarstwa domowe) na ich potrzeby produkcyjne, technologiczne i bytowe. Zużycie końcowe nie obejmuje przetwarzania na inne nośniki. Wsad i potrzeby energetycznych przemian oraz straty powstałe u producentów i dystrybutorów nie są tutaj uwzględnione. W zużyciu końcowym uwzględnia się natomiast paliwo na produkcję ciepła wykorzystywanego przez wytwórcę. Całkowite zużycie finalne jest podzielone na dwie części: zużycie energetyczne oraz zużycie nieenergetyczne (surowcowe) (Berent-Kowalska et al. 2014).

Zdefiniowane wcześniej zużycie finalne jak i pozyskiwanie energii słonecznej zostało zamodelowane w celu wyznaczenia ich wartości w zadanym horyzoncie czasowym. W tym celu posłużono się modelem wywodzącym się z metodologii szarych systemów. Ważną cechą modelowania za pomocą „szarych modeli” (GM ang. Grey Models) jest to, że w oparciu o zbudowany model względnie łatwo można dokonać prognozy np. kilka kroków w przód. Niewielka liczba danych potrzebna do wyznaczenia parametrów istotnie różni modele typu „szarego” od innych metod modelowania matematycznego lub numerycznego (Deng 1982, Zhang et al. 2003, Wang et al. 2005, Zhang et al. 2007). Niewielka liczba obserwacji konieczna do oszacowania parametrów modelu pozwala także na zastosowanie przesuwnej okna wykorzystującego tylko „najświeższe” obserwacje, czyni tę metodę adaptacyjną i jest szczególnie ważne, gdy dane zmieniają swój charakter w czasie i najstarsze obserwacje nie powinny być już uwzględniane w budowie prognozy. Takie podejście zwiększa istotnie dokładność tej metody.

Modele GM mają swoje korzenie w teorii szarych systemów, zaproponowanej przez chińskiego badacza J. L. Deng w roku 1982 (Deng 1982, Zhang et

al. 2003, Wang et al. 2005, Zhang et al. 2007, Kayacan et al. 2010, Lin, Yang 2003, Yao, Chi 2004, Trivedi, Singh 2005, Deng 1982, Guo 2005, Lin, Yang 2003, Sijing et al. 1993, Lim et al. 2012, Dang, Song 2012). Szary system jest modelem obiektu, w strukturze którego znajduje się mało dostępnych oraz użytecznych informacji. Teoria szarych systemów posiada wiele zastosowań, a mianowicie w: sterowaniu (Deng 1982), naukach społecznych, ekonomii (Lin, Yang 2003), geologii (Sijing et al. 1993), metodach modelowania podejmowania decyzji (Zhang et al. 2003), przewidywaniu ceny zamknięcia aukcji on-line (Cempel, Tabaszewski 2007), przewidywaniu elastyczności dochodowej popytu konsumpcyjnego (Dang, Song 2012), prognozowaniu stężeń pyłu zawieszonego w mieście (Peng, Dong 2011), prognozowaniu zużycia energii (Pai et al. 2011), jak również w naukach technicznych (Kayacan et al. 2010).

W pracy, do celów prognozowania zastosowano model szeregu czasowego oznaczonego w literaturze jako GM (1,1). Dzięki temu modelowi zbudowano prognozy pozyskania energii elektrycznej bazując na danych pochodzących z departamentu produkcji energii.

MODEL „SZAREGO SYSTEMU”

Model szarego systemu jest to ogólnie przyjęty model systemu, w strukturze którego nie ma wiele dostępnych użytecznych informacji. Przedstawia się go w postaci ogólnej równania różniczkowego (równania stanu) (Kayacan 2010):

$$\sum_{j=0}^m a_j \frac{d^{m-j} S^{(r)}}{dt^{m-j}} = \sum_{i=0}^{p-1} b_i P_i^{(r)} \quad (1)$$

gdzie:

$S^{(0)}(t)$, ($t = 1, 2, \dots, n$) – wektor pierwotnych obserwacji symptomu w dyskretnych chwilach czasowych,

$S^{(r)}$ – wektor danych systemów podlegający agregacji stopnia (r)

$P_i^{(r)}$ – wektor wejść sterowań (jak w każdym układzie)

a_j oraz b_i – współczynniki podlegające identyfikacji

Pierwotny (obserwowany) szereg czasowy można wyrazić jako:

$$S^{(0)} = \{S^{(0)}(t), S^{(0)}(t+1), \dots, S^{(0)}(t+n)\} \quad (2)$$

Szereg ten podlega operacji agregacji. W praktyce, by uprościć równanie, stosuje się agregację stopnia pierwszego.

Ogólnie agregacja stopnia r polega na zastosowaniu operacji AGO (ang. Accumulated Generating Operation), która sprowadza się do kumulacyjnego sumowania wyrazów szeregu wg wzoru [2]:

$$S^{(r)}(\tau) = \sum_{t=1}^{\tau} S_k^{(r-1)}(t) \quad (3)$$

gdzie:

τ – chwila czasowa dla której wyliczana jest suma skumulowana.

Operacja AGO jest bardzo istotna w omawianej metodzie, gdyż sumowanie skumulowane wygładza chwilowe fluktuacje i w zasadzie umożliwia dopasowanie modelu liniowego do otrzymanego szeregu (Deng 1989, Zhang et al. 2003, Wang et al. 2005, Zhang et al. 2007).

MODEL GM(1,1)

Model GM (1,1) jest najprostszym przybliżeniem szarego systemu, w którym parametry p i m we wzorze (1) równe są jedności. Na podstawie (1) można więc zapisać (Deng 1989, Zhang et al. 2003, Wang et al. 2005, Zhang et al. 2007, Kayacan et al. 2010, Lin, Yang 2003, Yao, Chi 2004, Trivedi, Singh 2005, Deng 1982, Guo 2005):

$$\frac{dS^{(1)}}{dt} + aS^{(1)} = b \quad (4)$$

Przechodząc do postaci dyskretniej, równanie (3) można zapisać w sposób uproszczony posługując się różnicami skończonymi:

$$\frac{S^{(1)}(t+1) - S^{(1)}(t)}{\Delta t} + \frac{a}{2}(S^{(1)}(t+1) + S^{(1)}(t)) = b \quad (5)$$

Pierwsze wyrażenie z lewej jest dyskretnie wyrażoną pochodną „ S ” względem czasu, natomiast drugie stanowi uśrednienie dwóch wyrazów szeregu skumulowanego.

Przyjmuje się, że krok pomiarowy jest stały i nie ma znaczenia w dalszych rozważaniach. Wynika to z faktu, że równanie można obustronnie pomnożyć przez Δt i rozpatrzeć nowe parametry modelu a i b , które są iloczynem pierwotnych stałych i stałego kroku czasowego. Wyznaczając różnicę pomiędzy wyrazami szeregu otrzymanego po operacji AGO otrzymuje się:

$$S^{(1)}(t+1) - S^{(1)}(t) = \sum_{\tau=1}^{t+1} S^{(0)}(\tau) - \sum_{\tau=1}^t S^{(0)}(\tau) = S^{(0)}(t+1) \quad (6)$$

Oznaczając z kolei średnią sumę elementów szeregu po operacji AGO:

$$z(t) = -\frac{1}{2}(S^{(1)}(t+1) + S^{(1)}(t)) \quad (7)$$

otrzymuje się ostatecznie model liniowy, z którego szacuje się nieznanne parametry a i b , zgodnie z zależnością [12]:

$$S^{(0)}(t+1) = az(t) + b \quad (8)$$

Wektor kolumnowy współczynników modelu wyznacza się z układu równań, przy czym ze względu na większą liczbę równań niż niewiadomych, wyznaczenia tego dokonuje się z zastosowaniem metody najmniejszych kwadratów:

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = (Z^T Z)^{-1} Z^T Y \quad (9)$$

Odpowiednie macierze Z i Y mają postacie:

$$Y = \begin{bmatrix} S^{(0)}(2) \\ S^{(0)}(3) \\ \dots \\ S^{(0)}(n) \end{bmatrix} \quad Z = \begin{bmatrix} z(1) & 1 \\ z(2) & 1 \\ \dots & \dots \\ z(n-1) & 1 \end{bmatrix} \quad (10)$$

Kolumna jedynek w macierzy Z pozwala wyznaczyć wartość wyrazu wolnego b.

PROGNOZA ZA POMOCĄ MODELU GM(1,1)

Do prognozy dochodzi się rozwiązując w sposób ścisły równanie (3). Łatwo to zrobić stosując metodę rozdzielania zmiennych co prowadzi do (Kayacan et al. 2010):

$$\hat{S}^{(0)}(T+1) = \left(S^{(0)}(1) - \frac{\hat{b}}{\hat{a}} \right) \exp(-\hat{a}T) (1 - \exp(\hat{a})) \quad (11)$$

gdzie: (T+1) to numer prognozowanego elementu uzależniony od poprzedniego elementu znanego w chwili czasu T, oraz a,b, są oszacowanymi wcześniej parametrami.

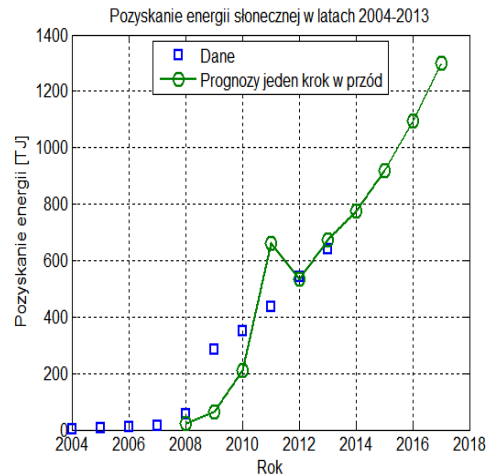
Model GM (1,1) –metoda ruchomego okna

Optymalnym rozwiązaniem budowania prognozy za pomocą modelu GM (1,1) jest metoda ruchomego okna, w której do oszacowania parametrów wykorzystuje się tylko część dostępnych danych z pominięciem najstarszych. Możliwość zastosowania takiej techniki wynika z faktu, że modelu GM (1,1) można użyć już dla niewielkiej liczby dostępnych danych. Takie podejście pozwala poprawić dokładność prognozy, gdyż pod uwagę bierze się fragment ostatnio uzyskanych danych, adaptacyjnie dostosowując się do zmian trendu.

Podsumowując metodę ruchomego okna, można wymienić jej cechy (Cempel, Tabaszewski 2007):

- oszacowanie parametrów modelu wymaga niewielu obserwacji, stąd można zastosować okno czasowe ignorując zbyt „stare” obserwacje,

- szacowanie parametrów w oknie pozwala adaptować się modelowi do zmian charakteru trendu, co jest szczególnie ważne przy występowaniu punktów przelomowych trendu i zmianach jego charakteru,
- ekstrapolacja poza przedział obserwacji zależy tylko od ostatnich („najważniejszych”) obserwacji, co przy założeniu utrzymania „lokalnej” tendencji w czasie powinno zmniejszyć błędy prognozy.



Rys. 1. Prognozy pozyskania energii słonecznej w Polsce do końca 2017r (okno4/horyzont4)

Jak wynika z rysunku 1 od 2009r zaobserwowano znaczny wzrost pozyskania energii słonecznej w Polsce, wiąże się to z politycznym nastawieniem ochrony środowiska, redukcji emisji spalin, co wiąże się zwiększonym pozyskaniem energii słonecznej. Wg modelu należy spodziewać się utrzymania tej tendencji i osiągnięcia pod koniec 2017 roku wartości ok. 1300 TJ pozyskania czystej energii. Jakość modelu można ocenić szacując błędy prognozy ex-post dla dostępnych danych. Przykładowo w 2013r błąd względny prognozy wynosił ok. 5,3%.

Tabela 1. Prognoza pozyskania energii słonecznej w Polsce okno4/horyzont4 (Berent-Kowalska et al. 2013)

Rok	Dane [TJ]	Prognozy [TJ]	Błąd bezwzględny [TJ]	Błąd względny [%]	Dane [MWh]	Dane prognoz [MWh]
2004	3,6				1000	
2005	6,3				1750	
2006	10,6				2944	
2007	15				4167	
2008	54	22,2	31,8	58,9	15000	6166,7
2009	283,4	65,18	218,22	77,0	78723	18105,7
2010	350	208,81	141,19	40,3	97223	58003,2
2011	434,4	660,16	225,76	52,0	120668	183379,2
2012	544	534,14	9,86	1,8	151112	148373,4
2013	639,3	673,11	33,81	5,3	177585	186976,5
2014		774,29				215082,3
2015		918,17				255049,3
2016		1096,88				304691,3
2017		1299,6				361008,4


Błąd prognozy można w tym przypadku uznać za dopuszczalny. Relatywnie większe błędy prognozy na lata 2008-2011 wynikają z gwałtownej zmiany trendu aż do roku 2011. Model po uwzględnieniu kolejnych danych adaptuje się do zmian i nadąża za nimi z pewnym opóźnieniem dlatego też błąd prognozy w 2012r zmalał do 1,8%.

Zużycie energii słonecznej w Polsce w handlu i usługach (okno4/horyzont4)

Na rysunku 2 Przedstawiono przykładową prognozę zużycia energii słonecznej w handlu i usługach w Polsce pod koniec 2017r, z wykorzystaniem optymalnego okna o szerokości 4. Maksymalny horyzont prognozy tak jak poprzednio wynosił 4 kroki. Dla prognoz z produkcji jak i konsumpcji energii słonecznej optymalną szerokością okna prognozy była wartość 4. Dla takiego okna model generował najmniejsze błędy względne, natomiast wykorzystanie większych szerokości okna (o zwiększonej liczbie danych w modelu GM(1.1)) powoduje zwiększenie ich wartości.

Uwzględniając wspomnianą szerokość okna w budowanym modelu uzyskano prognozę na rok 2012 z błędem względnym na poziomie 2,64% w odniesieniu do wartości rzeczywistej. W przypadku roku 2010 błąd był zdecydowanie większy co było spowodowane tym, że model „nie zdążył” adoptować się do zmiany tendencji rozwojowej. Najnowsze dane, które powinny mieć zasadnicze znaczenie w budowie modelu są małoliczne w porównaniu do wszystkich danych rozpatrywanych w oknie co powoduje brak

adaptacji szczególnie dla szerszych okien. Wynika z tego, że kluczowe znaczenie ma tutaj dobór szerokości okna, które musi zapewniać minimalny błąd prognozy ex-post (obliczony na podstawie dostępnych danych). W tabeli 2 Przedstawiono wartości zilustrowane na rysunku 2 Oraz wyznaczony błąd dla roku 2013.



Rys. 2. Prognozy wykorzystania energii słonecznej w Polsce na handel i usługi do końca 2017r (okno4/horyzont4)

Tabela 2. Prognozy wykorzystania energii słonecznej w Polsce na handel i usługi do końca 2017r (okno4/horyzont4) (Berent-Kowalska et al. 2013)

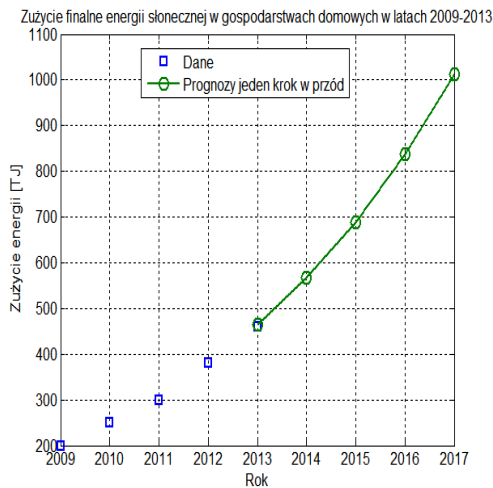
Rok	Dane [TJ]	Prognozy [TJ]	Błąd bezwzględny [TJ]	Błąd względny [%]	Dane [MWh]	Dane prognoz [MWh]
2004	3,6				1000,0	
2005	6,3				1750,0	
2006	10,6				2944,5	
2007	15				4166,7	
2008	54	22,2	31,8	58,9	15000,1	6166,72
2009	83,4	65,18	18,22	21,8	23166,9	18105,70
2010	100	158,18	58,18	58,1	27778,0	43939,24
2011	134,4	134,37	0,03	0,02	37333,6	37325,30
2012	164,2	168,53	4,33	2,64	45611,4	46814,26
2013	179,3	209,06	29,76	16,6	49805,9	58072,69
2014		208,48				57911,57
2015		233,19				64775,52
2016		266,28				73967,26
2017		299,83				83286,78

Tabela 3. Prognoza wykorzystania energii słonecznej w Polsce w gospodarstwach domowych do końca 2017r (okno4/horyzont4) (Berent–Kowalska et al. 2013)

Rok	Dane [TJ]	Prognozy [TJ]	Błąd bezwzględny [TJ]	Błąd względny [%]	Dane [MWh]	Dane prognoz [MWh]
2009	200				55556	
2010	250				69445	
2011	300				83334	
2012	379,8				105500	
2013	460	464,05	4,05	0,88	127778	128903,8
2014		566,99				157498,5
2015		688,23				191176,5
2016		837,65				232682,4
2017		1012,57				281271,7

Wykorzystanie energii słonecznej w gospodarstwach domowych (okno4/horyzont4)

Rysunek 3 przedstawia prognozę wykorzystania energii słonecznej w gospodarstwach domowych w Polsce. Zaobserwowano trend wzrostu wykorzystania energii słonecznej zobrazonej na rysunku 3. Utrzymująca się linia trendu zgodnie z rysunkiem 3 może być odzwierciedleniem dynamicznego inwestowania w pozyskanie energii słonecznej. W tym przypadku dysponując danymi od roku 2009 można zweryfikować Model GM(1.1) tylko w roku 2013. Wartość błędu względnego w tym przypadku wynosi 0,88%.



Rys. 3. Prognozy finalnego zużycia energii słonecznej w gospodarstwach domowych pod koniec 2017r w Polsce (okno5/horyzont4)

W tabeli 3 przedstawiono wartości liczbowe zamodelowanej prognozy zużycia finalnego energii słonecznej w gospodarstwach domowych w Polsce. Prognozy w tym przypadku są obarczone niewielkim błędem bezwzględnym na poziomie ok 4,05[TJ]. Z analizy danych wynika, że jeśli tendencja nadal zostanie utrzymana to na koniec 2017 roku spodziewane jest wykorzystanie energii słonecznej na poziomie 1012,57[TJ]. Prognozy te będą w pełni weryfikowane po opublikowaniu nowych danych z lat

2014-2016, ze względu na aktualizacje danych co 2 lata.

PODSUMOWANIE

Wzrost zapotrzebowania na energię w Polsce, (jej znaczące koszty dla konsumentów) perspektywy wyczerpania się zasobów naturalnych paliw kopalnych oraz ciągły nacisk ze strony rządu mający na celu ochronę środowiska naturalnego człowieka znacznie zwiększyło zainteresowanie źródłami czystej energii i w konsekwencji doprowadziły do dużego wzrostu ich produkcji. Obecnie rozwojowi czystej energii sprzyjają dotacje z Unii Europejskiej. Zgodnie z rozporządzeniami rządu otrzymano liczne dotacje za nadwyżkę produkcji energii z odnawialnych źródeł energii w gospodarstwach domowych. Sprzyja to rozpowszechnianiu zastosowania paneli słonecznych. Także, wciąż rozwijająca się dziedzina fotowoltaiki sprzyja zmniejszeniu kosztów instalacji małych elektrowni słonecznych.

Zgodnie z prognozami zawartymi w tabeli 1 zaobserwowano wzrost pozyskania energii słonecznej od 2009r. Zgodnie ze zidentyfikowanym poprzez model wzrostem trendu na rysunku 1 w 2017r przewiduje się, że pozyskanie czystej energii powinno kształtować się na poziomie 361008 [MWh]. Obecnie w Polsce wykorzystuje się 100% produkcji energii słonecznej co stwierdzono na podstawie otrzymanych prognoz. Podsumowując wartości prognoz z tabeli 2 i tabeli 3 wykorzystanie energii słonecznej powinno osiągnąć wartości ok. 1312,4 [TJ] na rok 2017. Przewidywane wartości pozyskania energii słonecznej na rok 2017 są rzędu 1299,6 [TJ], a zatem błąd bezwzględny pozyskania (tabela 1) energii słonecznej względem wartości prognoz zużycia energii słonecznej (tabela.2. oraz tabela.3.) wynosi 12,8 [TJ].

Duże znaczenie w zaprezentowanej metodzie ma możliwość budowy prognozy w oparciu o niewielką liczbę danych. W dodatku optymalny dobór okna, pozwalający na uwzględnienie charakteru trendu, daje pożądane rezultaty w postaci minimalnych błędów względnych prognozy.

LITERATURA

- Berent-Kowalska G., Kacprowska J., Moskal I., Jurgaś A., Kacperczyk G., 2014, *Główny Urząd Statystyczny. Energia ze źródeł odnawialnych w 2013 r.*, Warszawa
- Cempel C., Tabaszewski M., 2007, *Application of grey system theory in multidimensional machine condition monitoring*. Diagnostyka. 2, 11–18
- Dang L., Song B., 2012, *Analysis of the income elasticity of the consumer demand of Chinese rural residents and prediction of its trend*. Grey Syst.: Theory Appl. 2(2), 148–156
- Deng J.L., 1982, *Control problems of grey systems*. Syst.ControlLett., 5, 288–294
- Deng J.-L., 1989, *Introduction to grey system theory*. J.GreySyst., 1(1), 1–24
- Guo R., 2005, *Repairable system modelling via grey differential equations*. J.Grey-Syst. 8, 69–91
- Janiszewski J., Nawrowski A., 2015, *Zastosowanie teorii szarych systemów do prognozowania zużycia energii elektrycznej na przykładzie miasta Poznania. Między Ewolucją a rewolucją w poszukiwaniu strategii energetycznej*. Tom 1.
- Kayacan E., Ulutas B., Kaynak O., 2010, *Grey system theory-based models in time series prediction*. Expert Syst. Appl., 37, 1784–1789
- Lee Y.S., Tong L.I., 2011, *Forecasting energy consumption using a grey model improved by incorporating genetic programming*. Energy Convers. Manag., 52, 147–152
- Li G.D., Yamaguchi D., Nagi M.A. 2007. *GM(1,1). Markov chain combined model with an application to predict number of Chinese international airlines*. Technol. Forecast. Soc. Change. 74, 1465–1481
- Lin C.T., Yang S.Y., 2003, *Forecast of the output value of Taiwan's optoelectronics industry using the grey forecasting model*. Technol.Forecast.Soc.Change., 70, 177–186
- Lin Z., Zhang Q., Liu H., 2012, *Parameters optimization of GM(1,1) model based on artificial fish swarm algorithm*. Grey Syst. Theory Appl., 2(2), 166–177
- Lim D., Anthony P., Mun H.C., 2012, *Maximizing bidder's profit in online auctions using grey system theory's predictor agent*. GreySyst.: TheoryAppl. 2(2), 105–128
- Pai T.Y., Ho C.L., Chen S.W., 2011, *Using seven types of GM(1,1) model to forecast hourly particulate matter concentration in Banciao City of Taiwan*. Water Air Soil Pollut., 217, 25–33
- Peng Y., Dong M., 2011, *A hybrid approach of HMM and gray model forage-dependent health prediction of engineering assets*. Expert Syst.Appl. 38, 12946–12953
- Sijing C., Guangxu T., Hualin G. 1993. *Grey system theory applied to rock mechanics*. GeoMech. Abstr. 30, 473–478
- Trivedi H.V., Singh K.J., 2005, *Application of grey system theory in the development of a runoff prediction model*. Biosyst. Eng., 92(4), 521–526
- Wang T.C., Liou M.C., Hung H.H., 2005, *Application of grey theory on forecasting the exchange rate between TWD and USD*. Internal Conference of Business and Information. Conference paper, HongKong, 1–8
- Yao A.W.L., Chi S.C., 2004, *Analysis and design of a Taguchi-Grey based electricity demand predictor for energy management systems*. Energy Convers. Manag., 45, 1205–1217
- Zhang H., Li Z., Chen Z., 2003, *Application of grey modelling method to fitting and forecasting wear trend of marine diesel engines*. Tribol.Int., 36, 753–756
- Zhang L., Wang Z., Zhao S., 2007, *Short-term fault prediction of mechanical rotating parts on the basis of fuzzy-grey optimizing method*. Mech. Syst. Signal Process, 21, 856–865.