

doi:10.15199/48.2022.12.59

Metody szacowania wskaźnika nagromadzenia odpadów służącego do określenia lokalnego potencjału energetycznego z odpadów komunalnych na terenie gmin w Polsce

Streszczenie. W pracy sprawdzono przydatność wybranych metod prognostycznych do szacowania lokalnego wskaźnika ilości generowanych odpadów komunalnych a tym samym potencjału energetycznego odpadów, które będą mogły być wykorzystane w instalacjach termicznego przetwarzania odpadów. Prognozy stawiano w oparciu o metody: sztucznych sieci neuronowych (ANN), drzewa regresyjne (CART), wielozmienną regresję adaptacyjną z użyciem funkcji sklepanych (MARS), losowy las dla regresji (RFR), teorii zbiorów przybliżonych (RST), wzmacniane drzewa regresyjne (SRT) a także metody kombinowane będące połączeniem kilku metod prognostycznych.

Abstract. In this paper, the usefulness of selected forecasting methods was tested to estimate the local rate of municipal waste generation, and thus the energy potential of waste, which can be utilised in thermal waste treatment plants. Forecasts were made on the basis of the following methods: artificial neural networks (ANN), regression trees (CART), multivariate adaptive regression with glued functions (MARS), random forest for regression (RFR), rough set theory (RST), boosted regression trees (SRT), and combined methods which are a combination of several forecasting methods. (Methods for estimating the accumulation index of waste used to determine the local energy potential of municipal waste in communes in Poland)

Słowa kluczowe: potencjał energetyczny odpadów komunalnych, metoda szacowania wskaźnika masowego nagromadzenia odpadów, teoria zbiorów przybliżonych, sztuczne sieci neuronowe, model hybrydowy

Keywords: municipal waste energy potential, method for estimating mass accumulation rate, rough set theory, artificial neural networks, hybrid model

Wprowadzenie

Zwiększające się zapotrzebowanie na energię elektryczną stanowi wyzwanie dla gospodarki energetycznej, co wymusza podjęcie działań zmierzających do zapewnienia wymaganej w przyszłości ilości energii. Zgodnie z Prognozą zapotrzebowania na paliwa i energię do 2040 roku, stanowiącą załącznik nr 1 do Polityki Energetycznej Polski do 2040 roku, przewidywany wzrost zapotrzebowania na energię elektryczną finalną w najbliższych 20 latach wzrośnie o ok. 29% (z poziomu około 165 TWh w 2020 r. do około 230 TWh w 2040 r.) [1]. Zagwarantowanie dostaw energii elektrycznej na prognozowanym poziomie wiąże się z inwestycjami w branży energetycznej, które sprowadzą się do: rozbudowy mocy produkcyjnych, modernizacji polegającej na poprawie sprawności przetwarzania energii chemicznej paliwa na energię elektryczną, modernizacji sieci energetycznych w celu ograniczania strat przesyłowych [2]. Dodatkowym elementem mogącym w pewnym stopniu uzupełnić wciąż rosnące zapotrzebowanie na energię jest zagospodarowanie odpadów komunalnych. Stanowią one potencjalne źródło energii, której ilość uzależniona jest od stosowanej technologii energetycznego wykorzystania odpadów. Dominującą technologią w większości krajów europejskich (obok wykorzystania biogazu wysypiskowego) jest pozyskiwanie energii w procesie termicznej utylizacji odpadów. Wśród dostępnych procesów termicznego przekształcania odpadów komunalnych zdecydowanie dominują metody spalania [2-4]. Odzysk ciepła wytworzonego w procesie spalania odpadów i jego efektywne wykorzystanie stało się już obligatoryjne. Obecnie w Europie funkcjonuje ponad 500 spalarni odpadów komunalnych (z czego w Polsce działa 9 tego typu obiektów). Spalają one ponad 100 mln ton surowca. Funkcjonowanie instalacji spalania odpadów jako elektrowni, ciepłowni bądź elektrociepłowni uwarunkowane jest lokalnymi możliwościami i potrzebami w zakresie przesyłania oraz wykorzystania produkowanej formy energii. Najbardziej sprawny termicznie i elastyczny

eksploatacyjnie jest układ instalacji pracującej w skojarzeniu, to jest produkującej energię cieplną i elektryczną [3,5]. Nowoczesnymi, dużymi instalacjami termicznego przekształcania odpadów, które zostały wybudowane w Europie w ostatnich latach, są instalacje rusztowe [5]. Według danych zawartych w wytycznych najlepszej dostępnej techniki (BAT) z jednego megagrama odpadów komunalnych można przy pracy w układzie skojarzonym uzyskać ok. 0,4 MWh energii elektrycznej oraz ok. 6,6 GJ energii cieplnej netto [5]. Z uwagi, że zakłady termicznego przetwarzania odpadów stanowią ważny element sektora zagospodarowania odpadów komunalnych w Polsce, planowany jest rozwój tego typu instalacji. Zgodnie z zapisami zawartymi w Wojewódzkich Planach Gospodarowania Odpadami (WPGO), w najbliższych latach planowana jest budowa około 100 instalacji. Niestety aktualnie większość zebranych odpadów komunalnych (40%) jest składowana a tylko ok. 20% wykorzystywana jest do przekształcania termicznego z odzyskiem energii [16]. Lokalizacja, technologia i wielkość danego zakładu termicznego przetwarzania odpadów, oprócz wymagań ekologicznych i akceptacji społecznej, powinna uwzględniać wielkość strumienia odpadów komunalnych, który jest generowany na danym obszarze. Pozwoli to na oszacowanie potencjału energetycznego odpadów, które będą mogły być wykorzystane w instalacjach termicznego przetwarzania odpadów [2]. Wielkość odpadów najczęściej opisywana jest wskaźnikiem masowego nagromadzenia odpadów wyrażonym w $\text{kg} \cdot (\text{os} \cdot \text{rok})^{-1}$. Planowanie gospodarki odpadami komunalnymi wymaga uzyskania wiarygodnych danych na temat wytwarzania odpadów, czynników wpływających na ilość wytwarzanych odpadów oraz wiarygodnych prognoz ilości nagromadzonych odpadów w danym horyzoncie czasu. Badania nad prognozami ilości wytwarzanych odpadów stałych prowadzono na potrzeby planowania gospodarki odpadami komunalnymi na różnych poziomach, m.in. krajowym [6,7], regionalnym [8], a także w gospodarstwach domowych na terenach wiejskich i w miastach [9]. W badaniach tych do

modelowania wykorzystywano grupy zmiennych opisywane przez wskaźniki ekonomiczne, społeczne i infrastrukturalne. W prognozach wielkości wskaźnika masowego nagromadzenia odpadów wykorzystywane są głównie metody statystyczne w postaci modeli regresji liniowej [10], regresji wielokrotnej [11], teorii zbiorów przybliżonych [12], wielowymiarowych modeli szarych [13] oraz sztucznych sieci neuronowych [9,14]. Wykazano w nich, że wybór metody pozwalającej opracować model prognozujący ilość wytwarzanych odpadów komunalnych, stanowiący podstawę planowania gospodarki na danym obszarze, powinien uwzględniać szereg cech, co do których przewiduje się ich istotny wpływ na wynik końcowy. W istniejących opracowaniach brakuje porównań jakości i dokładności prognozy dla różnych modeli predykcyjnych, które bazują na tych samych zestawach cech, tym samym nie można jednoznacznie wskazać najlepszej metody szacowania wskaźnika nagromadzenia odpadów na danym obszarze. Dodatkowo w niniejszej pracy została postawiona hipoteza, że ilość odpadów komunalnych odbieranych z gospodarstw domowych, która może być przeznaczona na cele energetyczne zależy zarówno od typu administracyjnego gminy, jak i od czynników związanych z położeniem i funkcją społeczno-gospodarczą danego obszaru. Uważamy, że uwzględnienie czynników lokalizacyjnych i społeczno-gospodarczych pozwoli na zbudowanie modelu, który mimo znacznej zmienności terytorialnej umożliwi określenie wartości tego wskaźnika, a tym samym pozwoli oszacować potencjał energetyczny odpadów.

Cel i zakres pracy

Celem pracy było sprawdzenie przydatności wybranych metod prognostycznych do szacowania lokalnego wskaźnika ilości generowanych odpadów komunalnych a tym samym potencjału energetycznego odpadów, które będą mogły być wykorzystane w instalacjach termicznego przetwarzania odpadów. Dokonano również oceny wpływ budowy prognozy kombinowanej metodologią zaproponowaną przez Bates'a i Granger'a [15] z wykorzystaniem równych wag na jakość prognoz.

Prognozy stawiano w oparciu o metody: sztucznych sieci neuronowych (ANN), drzewa regresyjne (CART), wielozmienną regresję adaptacyjną z użyciem funkcji sklepanych (MARS), losowy las dla regresji (RFR), teorii zbiorów przybliżonych (RST) oraz wzmacniane drzewa regresyjne (SRT). W celu zapewnienia możliwości porównywania uzyskanych wyników zastosowano analogiczne założenia i ograniczenia w czasie budowy modeli jak w pracy Nęcka, Szul, Knaga [9]. Do badań pozyskano z Banku Danych Lokalnych GUS [16] oraz opracowań dotyczących typologii gmin w Polsce [17] następujące zmienne niezależne:

- C1 – typ administracyjny gminy
- C2 – struktura funkcjonalna gmin;
- C3 – gęstość zaludnienia na km^{-2} ;
- C5 – wskaźnik wielkości gospodarstwa domowego, w osobach na gospodarstwo domowe (na budynek $^{-1}$);
- C8 – udział gospodarstw osiągających dochód z działalności rolniczej;
- C9 – wskaźnik dochodu gminy jako udziału w podatkach od osób fizycznych na jednego mieszkańca gminy ($\text{zł} \cdot \text{na}^{-1}$);
- C10 – typologia gmin według zakresu oddziaływania;
- C11 – liczba gospodarstw;
- C12 – nazwa województwa.

Następnie na podstawie przeglądu literatury oraz wyników badań własnych wytypowano zestawy zmiennych niezależnych. Do szacowania strumienia odpadów komunalnych ogółem wybrano trzy zestawy: Z1 (C1, C2,

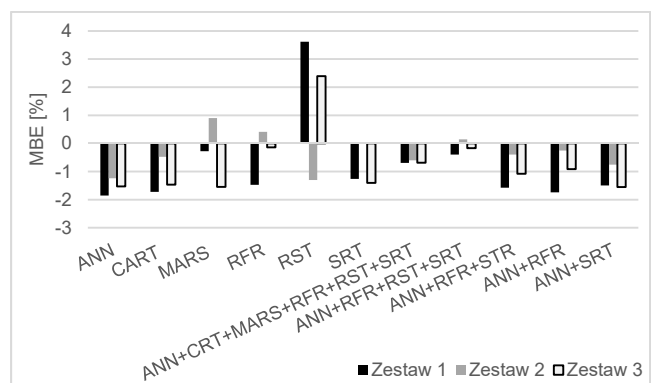
C10 i C12), Z2 (C1, C2, C5, C9, C12) i Z3 (C1, C2, C5, C9, C11, C12). Do jednego zestawu nie typowano zmiennych silnie z sobą skorelowanych. Ocena jakości opracowanych modeli przeprowadzono w oparciu o średni błąd systematyczny (MBE), współczynnik wariancji błędów średniokwadratowego (CV RMSE) i współczynnik determinacji (R^2), które są przyjmowane jako statystyczne wzorce oceny przez ASHRAE Guideline [18, 19]. Do oceny jakości wykorzystano również inne często stosowane w literaturze wskaźniki takie jak: MAE, MAPE [9, 12].

W celu uniknięcia nadmiernego dopasowania modeli do danych i obniżenia jego zdolności do generalizacji wyników na wstępie pracy obiekty zostały podzielone na dwa zbiory.

Do zbioru uczącego wybrano losowo 80% obserwacji, a na potrzeby opracowywania sztucznych sieci neuronowych wydzielono z niego 20% obserwacji, które utworzyły zbiór testowy. Zbiór walidacyjny, na którym sprawdzano jakości modeli utworzono z pozostałych obserwacji, które nie brały udziału w procesie budowy poszczególnych modeli. Ustalony podział obowiązywał we wszystkich realizowanych analizach.

Wyniki badań


W zastosowanych praktycznych w większości przypadków większą uwagę poświęca się analizie błędów dla zbioru walidacyjnego. Wskaźniki te pozwalają ocenić zdolność zbudowanego modelu do generalizacji. W dalszej części pracy dla tego zbioru danych przedstawiono analizę, której celem było wskazanie metody i zestawu zmiennych wejściowych do szacowania wskaźnika ilości generowanych odpadów komunalnych. Pierwszy z analizowanych wskaźników (MBE) oceniał na jakim poziomie jest udział różnic pomiędzy wielkością rzeczywistą a prognozowaną dla badanych obiektów. Z wykonanej analizy wynika, że najniższe wskaźnika MBE uzyskano dla metody losowego lasu (RFR) (Rys. 1). Średnia wartość wskaźnika dla wszystkich analizowanych zestawów zmiennych była na poziomie 0,7%. Najniższa jego wartość (0,02%) zarejestrowano dla wzmacnianych drzew regresyjnych (SRT), ale tylko przy wykorzystaniu drugiego zestawu zmiennych niezależnych. Wykorzystanie prognozy kombinowanej zbudowanej na bazie metod ANN, RFR, RST i SRT, pozwoliło na obniżenie błędu prognozy do poziomu średniego 0,24% a dla poszczególnych zestawów zmiennych oscylował on w przedziale od - 0,40% do 1,5%.



Rys. 1. Wskaźnik jakości MBE wybranych metod szacowania wielkości odpadów komunalnych

Drugim z zaleczanych przez ASHARE wskaźników oceny jakości modelu jest błąd CV RMSE. Jego wartość dla większości modeli oscylowała w przedziale od 35% do 45% (Rys. 2). Wyjątek stanowiła metoda teorii zbiorów przybliżonych dla drugiego zestawu zmiennych dla którego wynosiła ona 57%. Najniższe wartości wskaźnika CV RMSE występowały dla metody sztucznych sieci neuronowych (ANN) oraz losowego lasu (RFR) i był on na

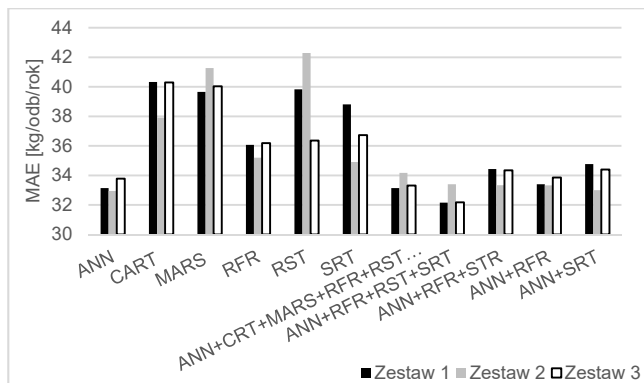
poziomie ok. 38%. W większości metod z wyjątkiem RST oraz metody MARS uzyskano dla drugiego zestawu zmiennych. Analogicznie jak dla wskaźnika MBE opracowanie prognozy kombinowanej pozwoliło na poprawę jej jakości. Najniższą wartość wskaźnika CV RMSE uzyskano dla kombinacji metod ANN, RFR, RST, oraz SRT. Kombinacja tych metod pozwoliła na postawienie prognoz dla których wartość analizowanego wskaźnika była na poziomie 35% niezależnie od wykorzystanego zestawu zmiennych niezależnych.



Rys. 2. Wskaźnik jakości CV RMSE wybranych metod szacowania wielkości odpadów komunalnych


W pracy oceniano również dopasowanie modelu do danych rzeczywistych na podstawie wskaźnika R^2 . Najwyższą jego wartość na poziomie 0,83 uzyskano dla sztucznych sieci neuronowych. Nieznacznie niższymi wartościami charakteryzował się losowy las oraz wzmacniane drzewa regresyjne. Dla wszystkich opracowanych modeli był on na poziomie powyżej 0,7 za wyjątkiem teorii zbiorów przybliżonych dla drugiego zestawu zmiennych. Opracowanie prognozy metodą kombinowaną pozwoliły na nieznaczny wzrost współczynnika dopasowania do poziomu 0,84.

Ocenę jakości zbudowanych modeli rozszerzono o analizę wskaźnika MAE (Rys. 3) oraz MAPE (Rys. 4). Są one również często spotykane w literaturze a ponadto pierwszy z nich pozwala na oszacowanie przeciętnego błędu prognozy wyrażonego w jednostkach określających wskaźnik masowego nagromadzenia odpadów. Opracowane modele szacowały roczną ilość odpadów z gospodarstwa domowego z błędem w zakresie od 33 do 42 kg/gosp/rok. Najniższą jego wartość uzyskano dla ANN oraz RFR niezależnie do zestawu zmiennych wejściowych. Budowa prognozy kombinowanej nieznacznie tylko poprawiła jakość modelu, ponieważ wartość błędu obniżyła się do poziomu 32 kg/gosp/rok dla metod ANN+RFR+RST+SRT. W innych kombinacjach zaobserwowano wzrost błędu prognozy względem ANN.



Rys. 3. Wskaźnik jakości MAE wybranych metod szacowania wielkości odpadów komunalnych

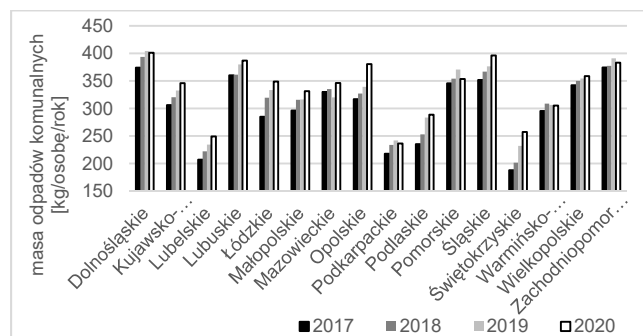
W ostatnim kroku oceny modeli dokonano analizy błędu MAPE. Najniższą jego wartość zarejestrowano dla ANN niezależnie od zestawu zmiennych wejściowych oraz dla metody RST ale tylko dla trzeciego zestawu zmiennych. Modelem RST charakteryzował się najniższym błędem na poziomie poniżej 22%. Był to poziom najniższy, którego nie osiągnięto nawet dla prognoz kombinowanych. Za praktycznym wykorzystaniem prognoz kombinowanych w oparciu o ANN+RFR+RST+SRT przemawia fakt, że generują one porównywalnej jakości prognozy niezależnie od zestawu zmiennych wejściowych.



Rys. 4. Wskaźnik jakości MAPE wybranych metod szacowania wielkości odpadów komunalnych


Przeprowadzona ocena jakości badanych modeli wskazała, że najlepszej jakości prognozy można oczekiwać wykorzystując metodę ANN dla której zmiennymi niezależnymi są zmienne C1, C2, C5, C9 oraz C12. Poprawę jakości prognoz można osiągnąć stosując kombinację metod. Z badania wynika, że najlepsze rezultaty uzyskano dla połączenia ANN, RFR, RST oraz SRT.

W ostatniej części pracy opracowane modele wykorzystano do wyznaczenia potencjału energetycznego odpadów zebranych z gospodarstw domowych. Na przestrzeni ostatnich lat widzimy systematyczny wzrost ilości zbieranych odpadów komunalnych (Rys. 5). Największą dynamikę wzrostu na przestrzeni lat 2017-2020 zaobserwowano dla województw łódzkiego, opolskiego i świętokrzyskiego. W skali kraju statystyczny mieszkaniec generuje ok. 340 kg odpadów rocznie.




Rys. 5. Wskaźnik ilości zbieranych odpadów komunalnych

Widoczna jest silna zależność pomiędzy wykorzystaniem zebranych odpadów. Zebrane odpady, jeśli nie są wykorzystywane do recyklingu, kompostowania czy termicznego przekształcenia trafiają na składowisko. Zależność pomiędzy przeznaczeniem odpadów na cele energetyczne i składowanie przedstawiono na rysunku 6. Najwyższe wykorzystanie zebranych odpadów na cele energetyczne występuje w województwach wielkopolskim i zachodniopolskim. Najniższe natomiast w świętokrzyskim i łódzkim w których ponad 50% odpadów jest składowanych.



Rys. 6. Struktura przeznaczenia zebranych odpadów komunalnych w poszczególnych województwach

Na podstawie zebranych danych oszacowano potencjał energii elektrycznej możliwej do uzyskania z termicznego przekształcania odpadów komunalnych dla poszczególnych województw przeliczeniu na mieszkańca. Średnia jego wartość jest na poziomie 84 kWh/(osobę·rok). Najwyższy potencjał występuje w województwie opolskim, zachodniopomorskim i lubuskim (Rys. 7). W celu wskazania potencjalnej lokalizacji zakładu termicznego przekształcania odpadów na terenie województwa oprócz uwarunkowań prawno-środowiskowych kluczowe znaczenie ma potencjał energetyczny odpadów gmin w danym rejonie.



Rys. 7. Potencjał energetyczny odpadów zebranych w poszczególnych województwach

Podsumowanie

Z wykonanej analizy wynika, że najlepszej jakości prognozy ilości odpadów komunalnych generowanych na terenie gminy można uzyskać metodą ANN. Dla metody tej zalecane jest wykorzystanie zmiennych niezależnych takich jak typ administracyjny gminy, typologia gminy według zakresu oddziaływania, struktura funkcjonalnej gminy oraz wskaźnik określający przeciętną liczbę osób w gospodarstwie domowym i nazwa województwa. Do preferowanych metod można również zaliczyć RFR i SRT. Nie daje ona jednak tak stabilnych wyników jak ANN. Metody te uzyskały najlepsze wyniki tylko dla II zestawu zmiennych niezależnych. Poprawę jakości prognozy można uzyskać wykorzystując prognozę kombinowaną na podstawie metod ANN, RFR, RST oraz SRT. Wykorzystanie tych metod pozwoliło na obniżenie błędu prognozy MBE poniżej 0,4%, CV RMSE oraz MAE do odpowiednio 35% i 32kg/gosp/rok a MAPE do 22%. Warto również zauważyć, że dla prognozy kombinowanych obniżył się wpływ zestawu zmiennych na jakość modelu. Potencjał energetyczny odpadów komunalnych w przeliczeniu na mieszkańca wynosi średnio 84 kWh/rok ale jego wartość zmienia się od 61 do 103 kWh/rok. Celowe są więc dalsze działania zmierzające do zwiększenia stopnia wykorzystania energetycznego zebranych odpadów komunalnych.

Autorzy: dr inż. Krzysztof Nęcka, Uniwersytet Rolniczy w Krakowie, Katedra Inżynierii Bioprocessów, Energetyki i Automatykacji,

ul. Balicka 116B, 30-149 Kraków, e-mail: k.necka@urk.edu.pl; dr inż. Tomasz Szul, Uniwersytet Rolniczy w Krakowie, Katedra Inżynierii Bioprocessów, Energetyki i Automatykacji, ul. Balicka 116B, 30-149 Kraków, e-mail: t.szul@urk.edu.pl.

LITERATURA

- [1] Ministerstwo Klimatu i Środowiska. Polityka Energetyczna Polski do 2040 r. <https://www.gov.pl/attachment/3c8a2fd6-a0a4-4b7f-b301-0b8569f1eaf7>
- [2] Klimek P. Ocena potencjału energetycznego odpadów komunalnych w zależności od zastosowanej technologii ich utylizacji. *Nafta-Gaz*, (2013), nr 12, 909-914
- [3] Przywarska R. Odpady komunalne źródłem energii odnawialnej. *Recykling*, (2009), nr 7, 103–104.
- [4] Tomasik M., Knaga J., Juliszewski T., Lis S., Szul T. Electrical properties of biocoal obtained by pyrolysis from energy plants. *Przegląd Elektrotechniczny*, 96 (2020), nr 1, 238-241
- [5] Wielgosinski G. Wybór technologii termicznego przekształcania odpadów komunalnych. *Nowa Energia*, (2012), nr 1, 66–80
- [6] Boas Berg A., Radziemska M., Adamcová D., Zloch J., Vaverková M.D. Assessment Strategies for Municipal Selective Waste Collection-Regional Waste Management. *Journal of Ecological Engineering*, (2018), vol. 19, 33–41
- [7] Mazzanti M., Zoboli R. Waste generation, waste disposal and policy effectiveness: evidence on decoupling from the European Union. *Resources, Conservation and Recycling*, (2008), vol. 52, 1221–1234
- [8] Vieira, V.H.A.D.M.; Matheus, D.R. The impact of socioeconomic factors on municipal solid waste generation in São Paulo, Brazil. *Waste Management & Research*, (2017), vol. 36(1), 79-85
- [9] Nęcka K., Szul T., Knaga J. Identification and Analysis of Sets Variables for of Municipal Waste Management Modelling. *Geosciences*, (2019), vol. 9(11), 458
- [10] Boer E.D., Jędrzyzak A., Kowalski Z., Kulczycka J., Szpadt R. A review of municipal solid waste composition and quantities in Poland. *Waste Management*, (2010), vol. 30, 369–377
- [11] Tałałaj I.A., Walery, M. The effect of gender and age structure on municipal waste generation in Poland. *Waste Management*, (2015), vol. 40, 3–8
- [12] Szul T., Knaga J., Nęcka K. Application of Rough Set Theory to Establish the Amount of Waste in Households in Rural Areas. *Ecological Chemistry and Engineering S.*, (2017), vol. 24, 311–325
- [13] Intharathirat R., Salam P.A., Kumar S. Untong, A. Forecasting of municipal solid waste quantity in a developing country using multivariate grey models. *Waste Management*, (2015), vol. 39, 3–14
- [14] Maryam A., Ali E.H. Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Management*, (2017), vol. 56, 13–22
- [15] Bates, J. M., Granger, C. W. The combination of forecasts. *Journal of the Operational Research Society*, (1969), vol. 20(4), 451-468
- [16] Główny Urząd Statystyczny. Główny Urząd Statystyczny. Bank Danych Lokalnych. 2022. Dostępne online: <https://bdl.stat.gov.pl/BDL/start> (dostęp 15 maja 2022).
- [17] Współczesna typologia obszarów wiejskich w Polsce – przegląd metodologicznych. Dostępny w Internecie: http://www.rcin.org.pl/Content/51257/WA51_70537_r2014-t86-z4_Przeg-Geogr-Banski.pdf (dostęp 24 października 2021 r.)
- [18] Ruiz G.R., Bandera C.R. Validation of Calibrated Energy Models: Common Errors. *Energies*, (2017), vol. 10, 1587
- [19] American Society of Heating, Ventilating, and Air Conditioning Engineers (ASHRAE). Guideline 14-2014, Measurement of Energy and Demand Savings; American Society of Heating, Ventilating, and Air Conditioning Engineers, (2014), Atlanta, GA, USA.