

Modelowanie zużycia energii na cele c.o. i c.w. w budynkach wielorodzinnych na tle sytuacji meteorologicznej we Wrocławiu

Modelling of heating energy demand in multi-family buildings depending on meteorological conditions in Wrocław

JOANNA KAJEWSKA-SZKUDLAREK, JUSTYNA STAŃCZYK, MAGDALENA DOMAŃSKA

DOI 10.36119/15.2024.5.2

Rosnące ceny za energię, a także przepisy związane z efektywnością energetyczną budynków powodują, że temat analiz zużycia energii na cele ogrzewnictwa i przygotowania ciepłej wody jest chętnie podejmowany przez zarządców budynków, a także środowisko naukowe. Dodatkowo, postępująca zmiana klimatu, coraz cieplejsze zimy, a bardziej upalne lata, wymagają wdrożenia głębszych analiz pobieranej energii w stosunku do zmieniających się warunków meteorologicznych. W niniejszym artykule przedstawiono wyniki badań modelowania zużycia energii przeznaczonej na c.o. i c.w. prowadzonych przy współpracy z jedną z wrocławskich spółdzielni mieszkaniowych. Wykazano, iż za pomocą prostej struktury regresyjnych drzew decyzyjnych istnieje możliwość utworzenia modelu miesięcznego zużycia ciepła dla mieszkalnictwa wielorodzinnego, przy jednoczesnym poznaniu reguł wpływu na ten aspekt stanu pogody. Współczynniki determinacji R^2 uzyskanych modeli oscylowały, w zależności od budynku, w zakresie od 0,93 do 0,96.

Słowa kluczowe: regresyjne drzewa decyzyjne, model zużycia, dobór predyktorów, ciepła woda, ogrzewanie, parametry meteorologiczne

Rising energy prices, as well as regulations related to the energy efficiency of buildings, make the issue of energy consumption for heating and hot water preparation analysis a subject of interest for building managers and the scientific community. Furthermore, progressive climate change, with increasingly warmer winters and hotter summers, requires the implementation of deeper analyses of energy intake in relation to the changing meteorological situation. This article presents the modelling results of the energy consumption for heating and hot water preparation, conducted in cooperation with one of Wrocław's housing cooperatives. It was shown that with the use of a simple structure of regression decision trees, it is possible to create a model of the heat consumption for multifamily housing, while learning the rules of the impact of weather conditions on this aspect. The determination coefficients R^2 of the models oscillated, depending on the building, in the range of 0.93 to 0.96.

Keywords: regressive decision trees, model of consumption, input variable selection, domestic hot water, heating, meteorological parameters

Wstęp

Duża część wyprodukowanej globalnie energii jest zużywana na potrzeby przygotowania ciepłej wody oraz ogrzewania pomieszczeń w budynkach, a także ich wentylację i klimatyzację [1, 2] i prognozuje się, że nie zmieni się to w najbliższej przyszłości [3]. Na przestrzeni ostatnich dziewięciu lat w różny sposób definiowano pojęcie energii w metodologii sporządzenia świadectw charakterystyki energetycznej budynków. W Rozporządzeniu Ministra Infrastruktury

i Rozwoju z dnia 27 lutego 2015 r. w sprawie metodologii wyznaczania charakterystyki energetycznej budynku lub części budynku oraz świadectw charakterystyki energetycznej oraz w zmianach do niego wprowadzonych w roku 2023 [4] wprowadzono pojęcia energii m.in. końcowej, użytkowej, pierwotnej, pomocniczej końcowej, odnawialnej energii pierwotnej. Aspekt klasyfikacji energii w świetle obowiązującego prawa został poruszony i wyjaśniony przez Kwiatkowskiego i Narowskiiego [5]. Szczegółowo wyodrębniła metoda bilansowa pozwala na pre-

cyjne określenie charakterystyki energetycznej budynków, a docelowo ma służyć także obliczeniu wskaźnika udziału źródeł energii odnawialnych w rocznym zapotrzebowaniu na energię końcową, tzn. energii dostarczonej do budynku lub części budynku z systemów technicznych.

Obserwowana aktualnie zmiana klimatu sprawia, że zima w klimacie umiarkowanym jest zdecydowanie cieplejsza [6], co wpływa na redukcję zapotrzebowania na ogrzewanie [7], natomiast w lecie obserwuje się coraz wyższe temperatury i dla utrzymania komfortu cieplnego

dr Joanna Kajewska-Szkudlarek <https://orcid.org/0000-0002-0253-8133>, dr inż. Justyna Stańczyk <https://orcid.org/0000-0002-5676-1787>, dr inż. Magdalena Domańska <https://orcid.org/0000-0003-3323-7648> – Uniwersytet Przyrodniczy we Wrocławiu, Instytut Inżynierii Środowiska, Wrocław. Adres do korespondencji/Corresponding author: joanna.kajewska-szkudlarek@upwr.edu.pl

wymagane są dłuższe okresy chłodzenia [6, 8]. Na podstawie zmienności liczby stopniociepła i chłodu Eurostat [9] szacował, że w Unii Europejskiej w 2021 zapotrzebowanie na ogrzewanie było o 11% mniejsze, a zapotrzebowanie na chłodzenie trzykrotnie większe w porównaniu z rokiem 1979. Pomimo tej tendencji, analizując łączne zużycie energii na cele c.o. i c.w., można zauważyć, że w Polsce na przestrzeni ostatnich dwudziestu lat, obserwowany jest jego wzrost z 659 PJ w 2002 do 782 PJ w 2021 [10], gdyż zakres czynników, które mają wpływ na zapotrzebowanie jest znacznie szerszy niż tylko sytuacja meteorologiczna np. zmiany liczby mieszkańców, efekt pandemii COVID-19, zawirowania na rynku paliw itp.

Z drugiej jednak strony, podążając za ideą gospodarki efektywnej energetycznie, niskoemisyjnej i przyjaznej klimatowi, sektor budowlany posiada znaczący potencjał jeśli chodzi o ograniczanie zużycia energii [11]. Jest on realizowany poprzez termomodernizację, stosowanie nowoczesnych systemów grzewczych i chłodzących, magazynowanie nadwyżek ciepła w systemach ciepłowniczych [12] oraz prognozowanie zapotrzebowania na ogrzewanie lub chłodzenie [13] mające zastosowanie w sterowaniu wyżej wymienionymi systemami. Predykcja wielkości zapotrzebowania na ciepło i ciepłą wodę pozwala na optymalizację pracy systemów ciepłowniczych [14, 15], co prowadzi do redukcji strat energii, kosztów eksploatacji systemów oraz zmniejszenia wielkości emisji zanieczyszczeń i pyłów [16] z zachowaniem komfortu cieplnego użytkowników. Ponadto, może wspomagać system rozliczania kosztów zużycia tych mediów [17]. Najczęściej poszukuje się zależności między pogodą a zapotrzebowaniem na ciepło lub chłód [1, 18]. Data mining i techniki inteligencji obliczeniowej aktualnie stanowią najbardziej nowoczesne podejście do tego zagadnienia wśród metod analizy danych [14, 15, 19].

Celem prac, opisanych w niniejszym artykule, było stworzenie modeli zużycia energii, przeznaczonych na cele centralnego ogrzewania (c.o.) budynków oraz przygotowania ciepłej wody (c.w.), z wykorzystaniem drzew regresyjnych. Obszar badań obejmował cztery budynki wielorodzinne, należące do jednej z wrocławskich spółdzielni mieszkaniowych. Na podstawie miesięcznych danych pochodzących z okresu 12.2013-02.2023 zbudowano modele uwzględniające zależność poboru energii od parametrów meteorologicznych. Dodatkowo, dokonano

oceny istotności poszczególnych zmiennych objaśniających (predyktorów) w modelowaniu.

Wprawdzie korelacja warunków pogodowych ze zużyciem ciepła, szczególnie w okresie grzewczym, jest zdecydowanie większa niż ze zużyciem ciepłej wody, jednak spółdzielnie rozliczają się z dostawcami za łączne zużycie tych dwóch mediów. W związku z tym, w niniejszej pracy modele zostały utworzone dla łącznej wielkości energii potrzebnej na cele przygotowania c.o. i c.w., mimo że udział ciepła przeznaczony na c.o. w ogólnej wielkości konsumpcji jest więk-

szy (65,1%) niż na przygotowanie ciepłej wody (17,3%) [10] i w zdecydowanie większym stopniu zależy od pogody.

Obszar badań i dane

Budynki, w których analizowano zużycie ciepła na cele c.o. i c.w., zlokalizowane są w centrum Wrocławia, w obrębie historycznej dzielnicy Fabryczna. Długość przesyłowej sieci ciepłowniczej miasta Wrocław w 2023 roku wynosiła 407 km, przy czym zaznaczyć należy, że jest stale rozbudowywana na przestrzeni lat. Sprzedaż energii na analizowane cele jest także



Rys. 1. Budynki wielorodzinne stanowiące obszar badań a-b) LG, c-d) ST, e-f) DK, g-h) RB, źródło: archiwum własne (zdjęcia z lewej); OpenStreetMap (fragmenty mapy z prawej)
Fig. 1. Multi-family buildings constituting the research area a-b) LG, c-d) ST, e-f) DK, g-h) RB, source: own archive (photos on the left); OpenStreetMap (map fragments on the right)

coraz większa i tak w roku 2015 wynosiła 7069,1 TJ, natomiast w 2023 była już o 15% wyższa (8091,7 TJ), z czego 78% była przeznaczona dla budynków mieszkalnych [20]. Fotografie oraz położenie na mapie obiektów będących obszarem badawczym przedstawiono na rysunku 1. Różnią się one pod względem struktury, a także czasu budowy (lata 1951-1984) i termomodernizacji (lata 1996-2013). Najstarszy budynek, Strzegomska (ST), został wybudowany w 1952 r., natomiast najnowszy to Dokerska (DK), który powstał w 1984 r. ST i RB (Robotnicza) są podobne pod względem wielkości – powierzchnia użytkowa to ok. 3 tys. m² i 6 kondygnacji łącznie z piwnicą. DK i LG (Legnicka) są większe – odpowiednio 11 i 9 kondygnacji, natomiast ich powierzchnia użytkowa to ponad 4 tys. m². Najwięcej mieszkańców zamieszkuje budynek położony na ul. Legnickiej (223 mieszkańców) a najmniej na Strzegomskiej (157 mieszkańców). LG, ST oraz RB są zlokalizowane względem kierunków geograficznych w układzie NNE-SSW, podczas gdy DK w układzie N-S, co może mieć wpływ na wielkość zużycia ciepła w związku np. z nagrzewaniem się budynku w słoneczne dni lub jego wychładzaniem przez wiatr, co ma też związek z liczbą kondygnacji poszczególnych budynków. Szczegóły techniczne dotyczące poszczególnych budynków zaprezentowano w tabeli 1.

Tabela 1. Charakterystyka analizowanych budynków
Table 1. Characteristics of the analyzed buildings

	LG	ST	DK	RB
liczba mieszkań	126	76	89	86
liczba mieszkańców	223	157	190	162
łączna powierzchnia mieszkań [m ²]	4 393	3 179	4 145	3 289
liczba lokali usługowych	0	0	2	2
powierzchnia lokali usługowych [m ²]	0	0	72	135
powierzchnia użytkowa [m ²]	4 393	3 179	4 217	3 424
kubatura [m ³]	17 000	9 720	15 010	8 750
liczba kondygnacji	9+piwnica	5+piwnica	11+piwnica	5+piwnica
rok budowy	1966	1952	1984	1970
materiały budowlane	ściany betonowe prefabrykowane i cegła żerańska	murowany z cegły i gazobetonu	wielka płyta	obiekt prefabrykowany płyty żuzłobetonowe
rok termomodernizacji	2013	2010	1996	2013
zużycie energii 2014-2022 [GJ/rok/m ²]	0,631	0,657	0,662	0,649
zużycie energii 2014-2022 [GJ/rok/osoba]	12,438	13,293	14,693	13,724

Miesięczne zużycie energii na cele c.o. i c.w. w latach 2013-2023 w analizowanych budynkach uzyskano w ramach współpracy ze spółdzielnią mieszkaniową SM Plener. Spółdzielnia dysponuje historycznymi dziesięcioletnimi danymi na temat zużycia ciepła i ciepłej wody, m.in. z rozliczeń pochodzących od lokalnego

dostawcy tych mediów. Odpowiadające im miesięczne wartości parametrów meteorologicznych pochodzą ze stacji IMGW-PIB Wrocław-Strachowice.

Analiza średniego rocznego zużycia energii przeznaczonej na ogrzewanie budynków i wody wskazuje, że najwięcej konsumuje jej DK (14,693 GJ/rok/osobę; 0,662 GJ/rok/m²). Może to wynikać z faktu, że nie jest to jeden budynek a właściwie zespół dwóch wysokich budynków, co prawdopodobnie powoduje, iż wymiana ciepła z otoczeniem w ich przypadku przebiega inaczej niż dla LG, ST oraz RB. Ponadto, dużo wcześniej niż pozostałe przeszedł on termomodernizację (1996) i jej technologia różni się od zastosowanej w pozostałych przypadkach. Najmniej energii w przeliczeniu na powierzchnię i mieszkańca zużywa budynek największy (LG), odpowiednio 0,631 GJ/rok/m² oraz 12,438 GJ/rok/osobę, dla którego dane pochodzą z okresu bezpośrednio po termomodernizacji, która miała miejsce w 2013 r. (tabela 1). Należy jednak dodać, że wartość zużycia w GJ/rok/osobę jest szacunkowa, ponieważ bazuje na liczbie użytkowników deklarowanej przez mieszkańców, tymczasem ich rzeczywista ilość na przestrzeni 10 analizowanych lat wykazuje bardzo dużą zmienność. Czynnikiem, który na nią wpływa we Wrocławiu jest m.in. jego akademicki charakter. Według danych GUS w roku akademickim

2022/2023 studiowało w mieście 105 tys. studentów [21], z czego duża część pochodziła spoza miasta. Najczęściej zamieszkują oni budynki wielorodzinne a w okresie letnim wyjeżdżają do rodzinnych miejscowości, wracając dopiero w październiku. Dodatkowo, ostatnie dziesięciolecie to wzmożona imigracja ekonomiczna z kie-

runków wschodnich wraz z napływem uchodźców z Ukrainy w 2022 r. Obecnie 23% mieszkańców Wrocławia stanowią obywatele tego kraju [22].

Aktualnie, średnie krajowe zużycie energii w gospodarstwach domowych (c.o., c.w., gotowanie, oświetlenie) w przeliczeniu na 1 mieszkańca wynosi 24,6 GJ, co jest zbieżne ze średnim poziomem europejskim (24,5 GJ/osobę). Zgodnie ze strukturą tego zużycia w 2021 roku (c.o.: 65,1%; c.w.: 17,3%), średnia wielkość energii przeznaczona na c.o. i c.w. wynosi około 20,0 GJ/osobę [10].

Metodyka badań

W przypadku każdego z czterech budynków wielorodzinnych jako pełny zbiór meteorologicznych zmiennych niezależnych, do modelowania rozpatrywano miesięczne wartości parametrów związanych z termiką i wilgotnością powietrza, prędkością wiatru, zachmurzeniem i usłonecznieniem, ciśnieniem i opadem atmosferycznym. Dodatkowe predyktory stanowiły: liczba dni z wystąpieniem temperatury powietrza poniżej określonego progu (dla temperatury średniej dobowej założono w zakresie od 0,0 do 15,0°C; dla temperatury minimalnej od 0,0 do -10,0°C; dla temperatury na powierzchni gruntu poniżej 0,0°C), liczba dni z wystąpieniem opadu, prędkości wiatru >10 m/s oraz szronu. Pełen zbiór potencjalnych predyktorów do modelowania liczył łącznie 24 zmienne objaśniające.

Dobór najistotniejszych zmiennych spośród powyżej wymienionych przeprowadzono w programie Statistica z wykorzystaniem ogólnych modeli regresji. Zbiór wszystkich potencjalnych predyktorów zaprezentowano na wykresach Pareto, a zmienne z p<0,05 zostały uznane za istotne i użyte kolejno do budowy modeli zużycia energii na cele c.o. i c.w. z wykorzystaniem drzew regresyjnych.

Drzewa decyzyjne DT (ang. Decision Trees) są narzędziem uczenia maszynowego służącym do tworzenia prognozytycznych i opisowych modeli, między innymi dla ilościowych zmiennych zależnych. W niniejszych badaniach zostały zastosowane jako jeden z modeli uczenia, wdrożony w kontekście zadania regresyjnego (tzw. RT – Regression Trees), gdzie parametrami wejściowymi były dane meteorologiczne, a wyjściowym łączna wartość zużycia energii dla poszczególnych budynków (wyrażona w jednostce GJ). Drzewo jest graficznym modelem, który powstaje w wyniku podziału bazy danych na rozłączne podzbiory. Mają one taką

właściwość, że są maksymalnie jednorodną z punktu widzenia zmiennej zależnej. Budowa modelu to proces wieloetapowy. Na każdym etapie mogą być wykorzystywane inne predyktory, spośród których wybierane są te, które prowadzą do uzyskania najbardziej homogenicznych podzbiorów.

Na początku drzewa analizowany jest cały zbiór obserwacji (węzeł macierzysty), który zostaje podzielony na dwa lub więcej podzbiorów (węzły potomne). Na dalszych etapach węzeł potomny staje się macierzystym, gdy jest dalej dzielony, natomiast gdy pozostaje bez zmian zostaje węzłem końcowym, czyli liściem. Liczba liści określa wielkość drzewa a liczba krawędzi między wierzchołkiem a najbardziej odległym liściem to jego głębokość. Dużą zaletą DT jest ich prosta struktura i zrozumiałe reguły, co znacznie upraszcza interpretację analizowanych zjawisk i zachodzących pomiędzy zmiennymi zależności.

W badaniach zastosowano strukturę drzewa regresyjnego typu fine, co odnosi się do drzewa szczegółowej budowy, nieco większej złożoności w kontekście liczby gałęzi. Zasada budowy drzewa regresyjnego polega na poszukiwaniu podziału w węzle m na m_L (left) i m_R (right), tak aby suma kwadratów reszt SSE (m_i) była jak najmniejsza. Błąd sumy kwadratów reszt (SSE) to różnica między wartością obserwowaną a wartością przewidywaną, którą można obliczyć jako poniższe równanie (1):

$$SSE = \sum_{i=0}^n (y_i - f(x_i))^2 \quad (1)$$

gdzie:

y_i – jest i -tą wartością zmiennej modelowanej,

$f(x_i)$ – jest wartością modelowaną,

x_i – jest i -tą wartością zmiennej objaśniającej.

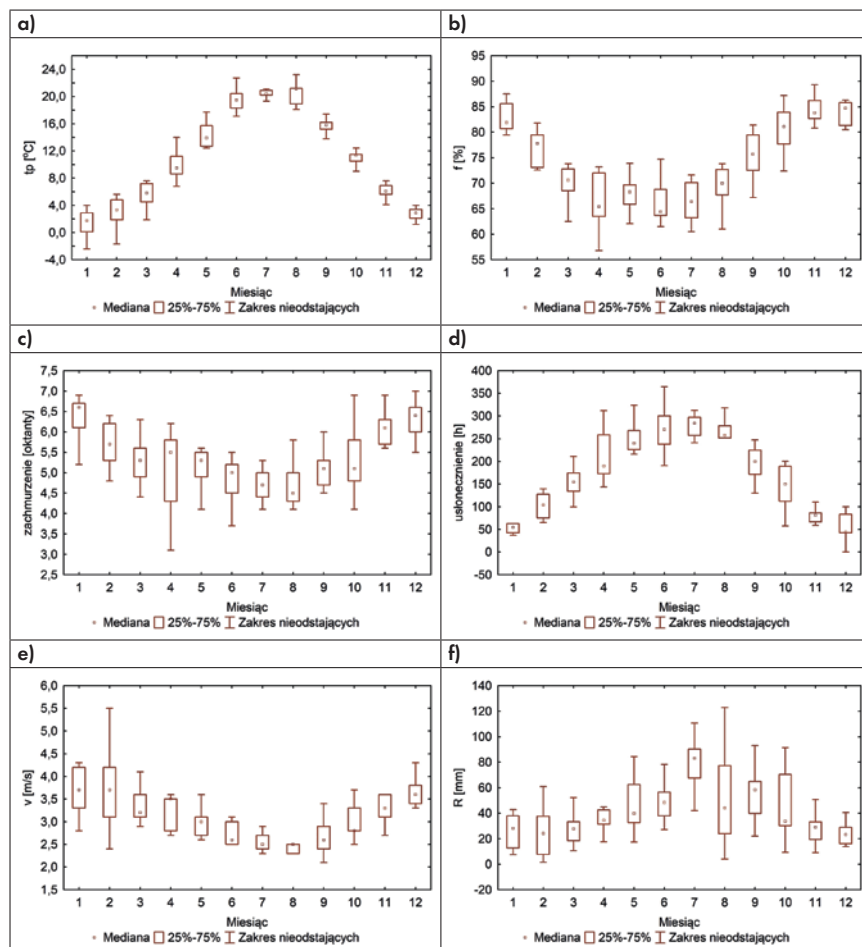
Jakość utworzonych modeli oceniano na podstawie metryk takich jak wielkość R^2 (współczynnik determinacji), średni błąd kwadratowy MSE (ang. Mean Squared Error), średni błąd bezwzględny MAE (ang. Mean Absolute Error). Zależność wielkości zapotrzebowania energii na c.o. i c.w. od poszczególnych predyktorów, na podstawie których zbudowano drzewa, wraz z ich strukturą przedstawiono na rysunkach drzew dla każdego z budynków. Cały zbiór danych obserwacyjnych podzielono na podzbiór uczący (70%) i testowy (30% wszystkich wartości), które poddano 10-krotnej walidacji krzyżowej.

Wyniki badań i dyskusja

Statystyczne charakterystyki (mediana, percentyle, zakres wartości nieodstających) parametrów meteorologicznych przedstawiono na rysunku 2. W analizowanym okresie 2013-2023 średnia miesięczna temperatura powietrza charakteryzuje się największym zakresem zmien-

ności sezonową zmienność omawianego zjawiska. W przypadku ST, DK i RB stycznia i kwietnia cechują się największym rozrzutem wartości, natomiast dla LG stycznia i lutego (rys. 3).

Pełen zestaw predyktorów (24 zmienne objaśniające) do stworzenia modeli drzew przedstawiono na rysunku 4. Te, które przekraczają próg $p=0,05$, wyznaczony czer-



Rys. 2.

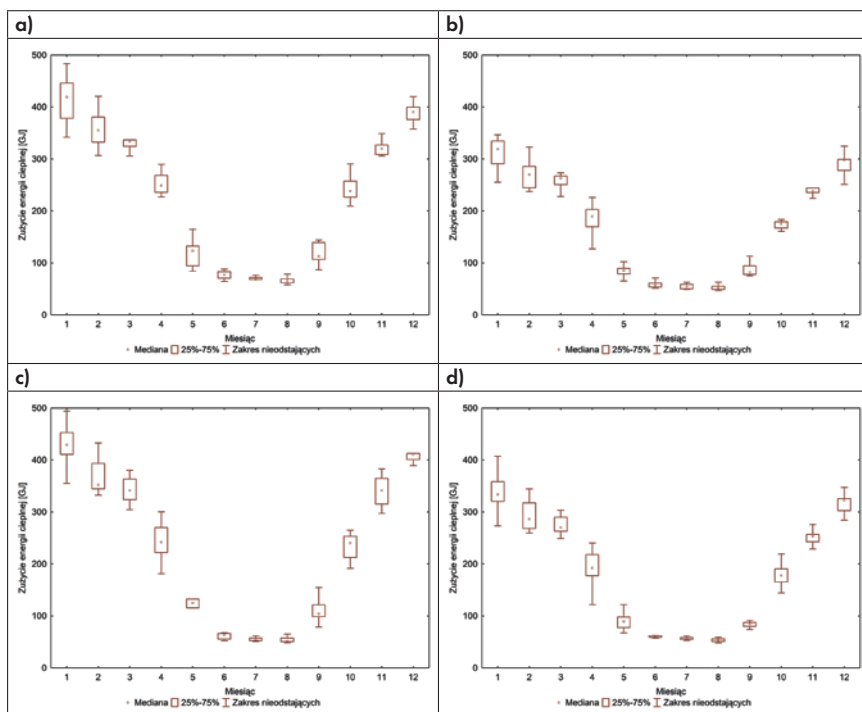
Charakterystyki statystyczne dla miesięcznych wartości parametrów meteorologicznych: a) temperatura powietrza, b) wilgotność względna powietrza, c) zachmurzenie, d) usłonecznienie, e) prędkość wiatru, f) opad atmosferyczny we Wrocławiu w latach 2013-2023

Fig. 2. Statistical characteristics for monthly values of basic meteorological parameters: a) air temperature, b) relative air humidity, c) cloud cover, d) sunshine duration, e) wind speed, f) precipitation in Wrocław in 2013-2023

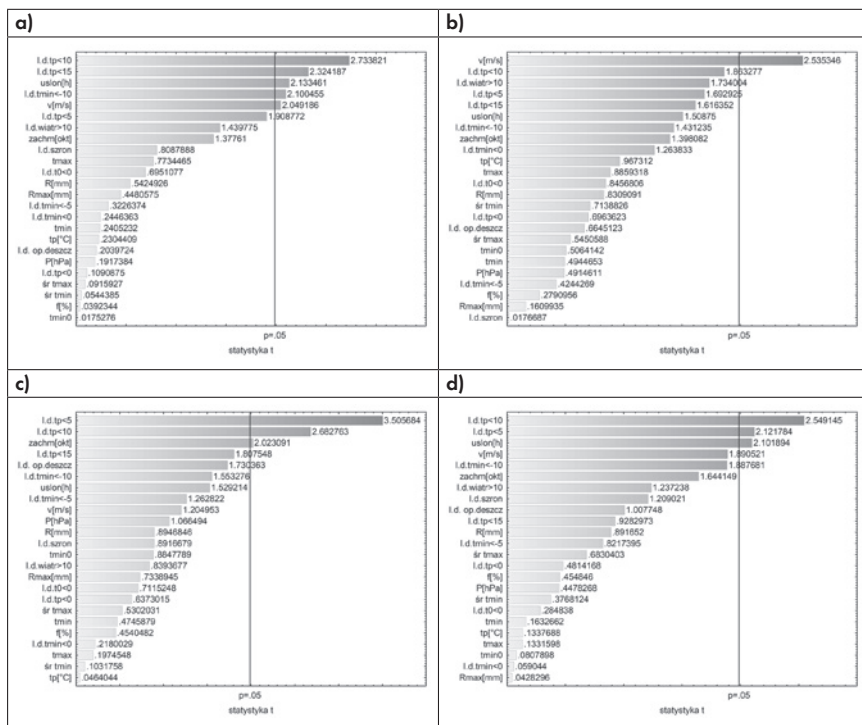
ności w lutym i kwietniu, podczas gdy wilgotność względna w kwietniu. Największy rozrzut wartości zachmurzenia obserwowano w kwietniu i październiku, natomiast usłonecznienia w kwietniu i czerwcu. Na przestrzeni 11 lat luty jest miesiącem o największej zmienności prędkości wiatru, a sierpień sumy opadu atmosferycznego. Które parametry meteorologiczne są istotne w modelowaniu zużycia energii i w jaki sposób na nie wpływają, zostało określone w kolejnych krokach badań.

Przebieg miesięcznego zużycia energii w analizowanych budynkach odzwier-

woną pionową linią, uznawano za istotne statystycznie. Analiza wykazała, że w budynkach DK (Dokerska) i RB (Robotnicza) istotnymi predyktorami są: liczba dni ze średnią dobową temperaturą powietrza niższą od $5,0^{\circ}\text{C}$ i $10,0^{\circ}\text{C}$ oraz zachmurzenie (DK) lub usłonecznienie (RB). O zużyciu energii w budynku ST (Strzegomska) istotnie decyduje jedynie prędkość wiatru. Drugi w kolejności predyktor stanowi liczba dni z temperaturą poniżej $10,0^{\circ}\text{C}$, dla której p wynosi $0,06$ i jest na granicy istotności. Prędkość wiatru może mieć wpływ na infiltrację budynków, która dotyczy niekontrolowanego, przypadkowego przepływu



Rys. 3. Charakterystyki statystyczne dla miesięcznego zużycia energii na cele c.o. i c.w. w analizowanych budynkach a) LG, b) ST, c) DK, d) RB w latach 2013-2023
 Fig. 3. Statistical characteristics for monthly energy consumption for heating and hot water preparing in the analyzed buildings a) LG, b) ST, c) DK, d) RB in 2013-2023



Rys. 4. Wykresy Pareto dla zużycia energii na cele c.o. i c.w. w analizowanych budynkach: a) LG, b) ST, c) DK, d) RB
 Fig. 4. Pareto charts for energy consumption for heating and hot water preparing in the analyzed buildings: a) LG, b) ST, c) DK, d) RB

powietrza, przenikania przez otwory i nieuszczelnności w przegrodach zewnętrznych. Ilość powietrza dostającego się w ten sposób do budynku trudno jest kontrolować, co niekorzystnie wpływa na jakość wentylacji.

Nadmierna infiltracja powoduje zaburzenia procesu wentylacji, może zmienić oczekiwany przepływ powietrza i zwiększać straty ciepła zimą. Dla zużycia na Legnickiej (LG) duże znaczenie mają: prędkość

wiatru, usłonecznienie, liczba dni z temperaturą dobową niższą od 10,0°C i 15,0°C, a także liczba dni z minimalną temperaturą powietrza mniejszą niż -10,0°C.

W sytuacji, gdy za istotne zmienne objaśniające uznano predyktory określające liczbę dni z temperaturą poniżej dwóch progów temperaturowych, do modelowania wybierano tę, która dotyczyła progów o wyższej temperaturze.

W przypadku budynku ST, dla którego jedynie prędkość wiatru okazała się znacząca, w modelowaniu uwzględniono także drugi, choć wg metody Pareto nieistotny, predyktor w kolejności, tzn. liczbę dni w miesiącu z temperaturą powietrza niższą od 10,0°C.

Wyniki modelowania zużycia energii na cele c.o. i c.w. z wykorzystaniem drzew regresyjnych przedstawiono w tabeli 2 a ich strukturę na rysunkach 5-8. Wartości świadczące o najlepszej jakości w podzbiore testowym, dla wszystkich analizowanych miar, zaznaczono kolorem szarym.

Najlepsze dopasowanie danych modelowanych do rzeczywistych w próbie testowej uzyskano dla najwyższego budynku (a właściwie dla zespołu dwóch budynków) spośród analizowanych, zlokalizowanego na ul. Dokerskiej ($R^2=0,96$), natomiast dla wszystkich pozostałych budynków wynosi on tyle samo ($R^2=0,93$). Dla Strzegomskiej (budynek najmniejszy pod względem liczby mieszkańców i mieszkań oraz powierzchni użytkowej) otrzymano najniższe błędy MSE i MAE (równe odpowiednio 629,27 i 18,83), podczas gdy dla Robotniczej najwyższe (1170,20 oraz 26,27). Dla budynków LG i DK, zdecydowanie wyższych od pozostałych i o podobnej powierzchni, uzyskano bardzo zbliżone wielkości błędów MSE i MAE.


Tabela 2. Wyniki modelowania zużycia energii na cele c.o. i c.w.
 Table 2. Results of thermal energy consumption for heating and hot water purposes modelling

LG	uczenie	test	ST	uczenie	test
R^2	0,94	0,93	R^2	0,91	0,93
MSE	702,47	828,78	MSE	902,00	629,27
MAE	18,45	21,32	MAE	22,54	18,83
DK	uczenie	test	RB	uczenie	test
R^2	0,89	0,96	R^2	0,89	0,93
MSE	2300,80	839,83	MSE	1957,10	1170,20
MAE	36,39	22,38	MAE	31,76	26,37

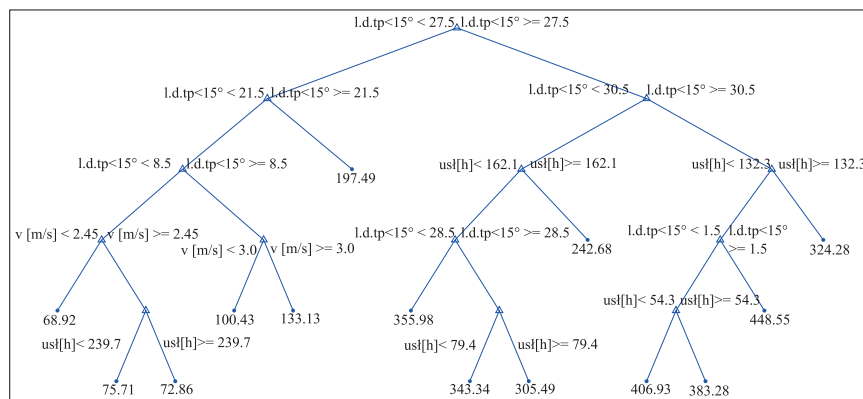
Analiza struktury utworzonych drzew wskazuje, że pierwszego podziału całego zbioru danych algorytm dokonał przy pomocy predyktora określającego liczbę dni w miesiącu z temperaturą średnią dobową poniżej 15,0°C dla LG oraz poniżej 10,0°C dla pozostałych budynków.

W przypadku Dokerskiej i Robotniczej 16 dni z taką temperaturą stanowi kryterium podziału zmiennej zależnej. Dla Strzegomskiej 10 dni, natomiast w przypadku Legnickiej i liczby dni w miesiącu z temperaturą <math>< 15,0^{\circ}\text{C}</math> jest ona równa 27.


Pozostałe predyktory, które zostały uznane za najistotniejsze w poprzednim kroku badań, dla wszystkich analizowanych budynków decydowały o podziale dopiero na trzecim poziomie gałęzi, co wskazuje, że mają one mniejsze znaczenie przy budowie drzewa niż liczba dni z temperaturą dobową poniżej określonego progu. Dla Legnickiej jest to usłonecznienie, pojawiające się również przy podziale na węzły końcowe – liście (rys. 5-8).



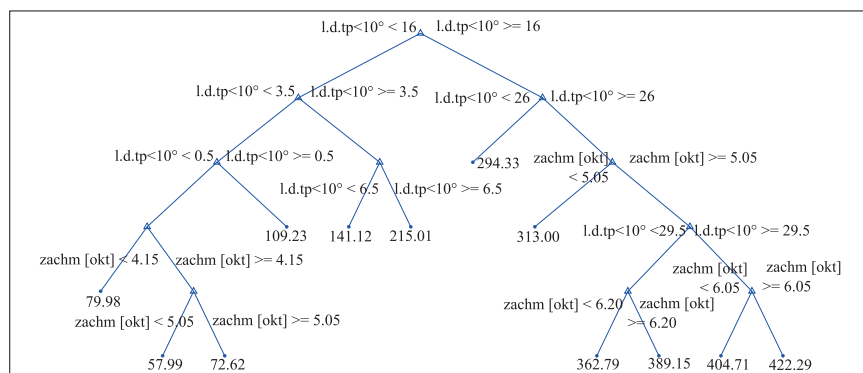
Rys. 8.
Drzewo regresyjne dla zużycia energii (GJ) w budynku RB
Fig. 8. Regression tree for energy consumption (GJ) in the RB building



Rys. 5.
Drzewo regresyjne dla zużycia energii (GJ) w budynku LG
Fig. 5. Regression tree for energy consumption (GJ) in the LG building



Rys. 6.
Drzewo regresyjne dla zużycia energii (GJ) w budynku ST
Fig. 6. Regression tree for energy consumption (GJ) in the ST building



Odniesienie do warunków meteorologicznych i klimatycznych stanowi istotny aspekt projektowania budynków. Jest przydatne w momencie obliczania zapotrzebowania na ciepło budynku lub podczas planowania prac dociepleniowych a także projektowania instalacji klimatyzacji i wentylacji. Aktualne regulacje w tym zakresie można znaleźć w normie PN-EN 12831-1:2017-08 dotyczącej instalacji grzewczych w budynkach i metody obliczania projektowego obciążenia cieplnego [23].

Parametry meteorologiczne mają wpływ na zużycie energii potrzebnej do ogrzania budynku. Ich wpływ na konsumpcję ciepłej wody do tej pory nie był szeroko badany. Często w modelach zakłada się stałą wartość jej zużycia, która nie podlega fluktuacjom w rytmie dobowym oraz sezonowym (i nie zależy od warunków otoczenia), jednak Weiler i Eicker [24] zwracają uwagę na wady takiego podejścia. Wydaje się, że ta tematyka wymaga podjęcia bardziej szczegółowych badań, zwłaszcza, że Horkai [25] wykazał zależność zużycia wody ciepłej od zewnętrznej temperatury powietrza. Zmienny rodzaj parametrów, które okazały się wpływać istotnie na zapotrzebowanie cieplne analizowanych budynków, jest spowodowany m.in. rokiem budowy poszczególnych bloków. Dla bloków najstarszych (tj. LG i ST) istotnym czynnikiem jest prędkość wiatru, co może sugerować dość znaczne straty ciepła m.in. przez stolarkę okienną. Według normy PN-EN 1991-1-4, zwanej normą wiatrową, obciążenie wiatrem różni się w zależności od rodzaju obiektu i jego gabarytów. Wysokość budynku, jego kształt i orientacja względem kierunku wiatru mają

Rys. 7.
Drzewo regresyjne dla zużycia energii (GJ) w budynku DK
Fig. 7. Regression tree for energy consumption (GJ) in the DK building

wpływ na obciążenie wiatrem [26]. Nie bez znaczenia jest także usytuowanie budynków względem kierunków świata, ponieważ wykazano istotność zachmurzenia i usłonecznienia w przypadku trzech z czterech analizowanych obiektów. Badania wykazały, że dla czterech wybranych lokalizacji najbardziej istotna jest liczba dni z temperaturą powietrza poniżej 10,0°C lub 15,0°C, ale także dostęp do energii słonecznej, który w znacznej mierze zależy od usytuowania budynku względem kierunków geograficznych.

Podsumowanie

Modelowanie zużycia energii na cele c.o. i c.w. w wybranych budynkach wielorodzinnych na podstawie parametrów meteorologicznych z zastosowaniem drzew regresyjnych dostarczyło zadowalających wyników. Świadczy o tym wysoka wartość współczynników R^2 (w próbie testowej powyżej 0,9) określających zależność danych modelowanych i rzeczywistych.

Istotnymi predyktorami do modelowania okazały się liczba dni ze średnią miesięczną temperaturą powietrza niższą od 5,0; 10,0; 15,0°C i liczba dni w miesiącu z minimalną temperaturą powietrza mniejszą od -10,0°C oraz prędkość wiatru, zachmurzenie i usłonecznienie. Zarówno metoda Pareto, jak i drzewa regresyjne wskazują, że liczba dni z temperaturą powietrza poniżej określonego progu temperaturowego ma większą wagę w modelach niż sama temperatura i pozostałe parametry meteorologiczne uznawane za mające wpływ na zużycie ciepła w budynkach mieszkalnych.

Model o najlepszej jakości otrzymano dla zespołu najwyższych budynków, zlokalizowanego na ul. Dokerskiej ($R^2=0,96$), natomiast dla pozostałych jest na podobnym poziomie ($R^2=0,93$). Dla budynku najmniejszego pod względem powierzchni użytkowej, liczby mieszkań i mieszkańców (Strzegomska) uzyskano najniższe błędy MSE i MAE (równe odpowiednio 629,27 i 18,83), podczas gdy dla Robotniczej najwyższe (1170,20 oraz 26,27). Dla budynków zlokalizowanych na Legnickiej i Dokerskiej, zdecydowanie wyższy od pozostałych i o podobnej powierzchni, wielkości błędów MSE i MAE są bardzo zbliżone (odpowiednio 828,78 i 21,32; 839,83 i 22,38).

Otrzymane wyniki wskazują, że drzewa regresyjne mogą być z powodzeniem stosowane do modelowania wielkości energii zużytej na potrzeby c.o. i c.w. w budynkach wielorodzinnych. Poznane zależności mają posłużyć do tworzenia modeli predykcyjnych, które stanowią kolejny etap badań. Prognoza zużycia energii na cele ogrzewania i przygotowania ciepłej wody może znaleźć zastosowanie

podczas rozliczania z dostawcami tych mediów, a także przy planowaniu automatyki sterowania systemami grzewczymi.

W połowie 2023 roku w mieszkaniach budynków należących do Spółdzielni dokonano instalacji czujników temperatury i wilgotności powietrza wewnętrznego. Autorzy mają w perspektywie przeprowadzenie oceny jej wpływu na wielkość zużycia analizowanych mediów.

Podziękowania

Autorzy manuskryptu pragną podziękować Spółdzielni Mieszkaniowej „Plener” we Wrocławiu za współpracę oraz udostępnienie danych do badań.

LITERATURA

- [1] Ling J., Dai N., Xing J., Tong H. An Improved Input Variable Selection Method of the Data-Driven Model for Building Heating Load Prediction. *Journal of Building Engineering* 44 (2021), 103255; doi: 10.1016/j.jobe.2021.103255
- [2] Salata F., Falasca S., Ciancio V., Curci G., Grignaffini S., de Wilde P. Estimating Building Cooling Energy Demand through the Cooling Degree Hours in a Changing Climate: A Modeling Study. *Sustainable Cities and Society* 76 (2022), 103518; doi: 10.1016/j.scs.2021.103518
- [3] Imhoff M. L., Bounoua L., Ricketts T., Loucks C., Harris R., Lawrence W. T. Global Patterns in Human Consumption of Net Primary Production. *Nature* 429(6994) (2004), 870–73; doi: 10.1038/nature02619
- [4] Dz.U. 2023 poz. 697, Rozporządzenie Ministra Rozwoju i Technologii z dnia 28 marca 2023 r. zmieniające rozporządzenie w sprawie metodologii wyznaczania charakterystyki energetycznej budynku lub części budynku oraz świadectw charakterystyki energetycznej
- [5] Kwiatkowski J., Narowski P. Energia dostarczona czy potrzebny nam jeszcze jeden rodzaj w klasyfikacji energii w charakterystyce energetycznej budynków? *Ciepłownictwo, Ogrzewnictwo, Wentylacja* 54/10 (2023), 13–16; doi: 10.15199/9.2023.10.2
- [6] Ciancio V., Salata F., Falasca S., Curci G., Golasi I., de Wilde P. Energy Demands of Buildings in the Framework of Climate Change: An Investigation across Europe. *Sustainable Cities and Society* 60 (2020), 102213; doi: 10.1016/j.scs.2020.102213
- [7] Pagliaro F., Cellucci L., Burattini C., Bisegna F., Gugliemetti F., de Lieto Vollaro A., Salata F., Golasi I. A Methodological Comparison between Energy and Environmental Performance Evaluation. *Sustainability* 7(8) (2015), 10324–42; doi: 10.3390/su70810324
- [8] Wang J., Hou J., Chen J., Fu Q., Huang G. Data Mining Approach for Improving the Optimal Control of HVAC Systems: An Event-Driven Strategy. *Journal of Building Engineering* 39 (2021), 102246; doi: 10.1016/j.jobe.2021.102246
- [9] Eurostat. Heating and Cooling Degree Days – Statistics. https://ec.europa.eu/eurostat/statistics-explained/index.php?Oldid=510067#Heating_and_cooling_degree_days_at_EU_level (2023)
- [10] Główny Urząd Statystyczny. Zużycie energii w gospodarstwach domowych w 2021 r., dostęp: https://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/5485/12/2/1/zuzycie_energii_w_gospodarstwach_domowych_w_2021_r.pdf
- [11] Abdou N., el Mghouchi Y., Jraida K. S., Hajou A., Mouqallid M. Prediction and Optimization

of Heating and Cooling Loads for Low Energy Buildings in Morocco: An Application of Hybrid Machine Learning Methods. *Journal of Building Engineering* 61(2022), 105332

- [12] Turski M. Magazynowanie ciepła w miejskich systemach ciepłowniczych. *Instal* 10 (2023), 4–8; doi: 10.36119/15.2023.10.1
- [13] Frayssinet L., Merlier L., Kuznik F., Hubert J.-L., Milliez M., Roux J.-J. Modeling the Heating and Cooling Energy Demand of Urban Buildings at City Scale. *Renewable and Sustainable Energy Reviews* 81 (2018), 2318–27; doi: 10.1016/j.rser.2017.06.040
- [14] Jing Z., Liu X. A Hybrid Method of Dynamic Cooling and Heating Load Forecasting for Office Buildings Based on Artificial Intelligence and Regression Analysis. *Energy and Buildings* 174 (2018), 293–308; doi: 10.1016/j.enbuild.2018.06.050
- [15] Zhao J., Duan Y., Liu X. Uncertainty Analysis of Weather Forecast Data for Cooling Load Forecasting Based on the Monte Carlo Method. *Energies* 11(7) (2018), 1900; doi: 10.3390/en11071900
- [16] Lin B., Ling C. Heating Price Control and Air Pollution in China: Evidence from Heating Daily Data in Autumn and Winter. *Energy and Buildings* 250 (2021), 111262; doi: 10.1016/j.enbuild.2021.111262
- [17] Bartnicki G., Nowak B. Predykcja zużycia ciepła w lokalu mieszkalnym na podstawie danych historycznych z ciepłomierzy mieszkaniowych. *Instal* 12 (2020), 15–20; doi: 10.36119/15.2020.12.2
- [18] Hosseini M., Javanroodi K., Nik V. M. High-Resolution Impact Assessment of Climate Change on Building Energy Performance Considering Extreme Weather Events and Microclimate – Investigating Variations in Indoor Thermal Comfort and Degree-Days. *Sustainable Cities and Society* 78 (2022), 103634; doi: 10.1016/j.scs.2021.103634
- [19] Bartnicki G., Nowak B. Możliwości predykcji zużycia ciepła w lokalu mieszkalnym za pomocą modeli autoregresji. *Instal* 5 (2021), 8–14; doi: 10.36119/15.2021.5.1
- [20] Urząd Statystyczny we Wrocławiu, Warunki życia – mieszkania i infrastruktura 2023, dostęp: https://wroclaw.stat.gov.pl/files/gfx/wroclaw/pl/defaultstronaopisowa/1602/1/2/dz_8_mieszkania_infrastruktura_2023.pdf
- [21] Urząd Statystyczny we Wrocławiu, Rocznik Statystyczny Wrocławia 2023, dostęp: <https://wroclaw.stat.gov.pl/publikacje-i-foldery/roczniki-statystyczne/rocznik-statystyczny-wroclawia-2023,3,18.html>
- [22] Centrum Analiz i Badań, Unia Metropolii Polskich, Miejska gościnność: wielki wzrost, wyzwania i szanse – Raport o urodzajach z Ukrainy w największych polskich miastach (2022), dostęp: <https://metropolie.pl/arttykul/34-mln-ukraincow-w-polsce-nowy-raport-unii-metropolii-polskich>
- [23] PN-EN 12831-1:2017-08 (wersja angielska) Instalacje ogrzewcze w budynkach Metoda obliczania projektowego obciążenia cieplnego
- [24] Weiler V., Eicker U. Individual Domestic Hot Water Profiles for Building Simulation at Urban Scale. *Proceedings of the 16th IBPSA Conference Rome, Italy, (2019)*, doi: 10.26868/25222708.2019.210467.
- [25] Horkai A. A statistical analysis of the relationship between domestic hot water consumption and mean outdoor temperature in Budapest. *IDŐJÁRÁS/QUARTERLY JOURNAL OF THE HUNGARIAN METEOROLOGICAL SERVICE* 125.1 (2021), 53–82
- [26] PN-EN 1991-1-4 Eurokod 1-4 Oddziaływania na konstrukcje – Część 1-4: Oddziaływania ogólne – Oddziaływania wiatru, Warszawa, Polski Komitet Normalizacyjny, 2018