

ZASTOSOWANIE LOGIKI ROZMYTEJ W ANALIZIE WARUNKÓW POGODOWYCH

Olga Malolepsza, Piotr Prokopowicz, Dariusz Mikołajewski

Uniwersytet Kazimierza Wielkiego
Wydział Informatyki
ul. Kopernika 1, 85-064 Bydgoszcz
e-mail: olga.malolepsza@ukw.edu.pl

Słowa kluczowe: Tematem artykułu jest wykorzystanie logiki rozmytej w procesie rozpoznawania i analizy warunków pogodowych. System rozmyty, który wykorzystano do rozpoznawania pogody, został stworzony przy użyciu Matlab, w aplikacji Fuzzy Logic Designer, skupiając się na integracji logiki rozmytej i technik sztucznej inteligencji (AI), pokazując możliwości oferowane przez systemy AI w zarządzaniu niepewnością. Model rozpoznawania pogody wykorzystuje trzy zmienne wejściowe w postaci maksymalnej temperatury, minimalnej temperatury i wiatru, a także 35 reguł, które generują prognozę pogody, a mianowicie opady, które mogą być bardzo niskie, niskie, normalne, wysokie i bardzo wysokie.

Słowa kluczowe: Logika rozmyta, analiza pogody, Matlab, sztuczna inteligencja, Mamdani, zbiory rozmyte

APPLICATION OF FUZZY LOGIC IN THE ANALYSIS OF WEATHER CONDITIONS

Abstract: The topic of this paper is the use of fuzzy logic in the recognition and analysis of weather conditions. The fuzzy system used for weather recognition was created using Matlab, in the Fuzzy Logic Designer application, focusing on the integration of fuzzy logic and artificial intelligence (AI) techniques, demonstrating the possibilities offered by AI systems in managing uncertainty. The weather recognition model uses three input variables in the form of maximum temperature, minimum temperature and wind, as well as 35 rules that generate a weather forecast, namely precipitation, which can be very low, low, normal, high and very high.

Keywords: Fuzzy logic, weather analysis, Matlab, artificial intelligence, Mamdani, fuzzy sets

1. WSTĘP

Pogoda to chwilowy stan atmosfery w danym miejscu, nad którym nie mamy pełnej kontroli, ale który w znacznym stopniu wpływa na życie człowieka [1]. Większość ludzi sprawdza pogodę przed podróżą, pracą lub uroczystością. Prognozy są kluczowe dla transportu, przemysłu, usług, analiz ekstremalnych zjawisk oraz wpływu pór roku na energię, w tym z odnawialnych źródeł. Prognozowanie pogody to jedno z najważniejszych i najtrudniejszych zadań służb meteorologicznych, stanowiące element systemu przewidywania warunków naturalnych [2-5]. W tym przypadku zbiory rozmyte są obiecującym narzędziem do modelowania i wnioskowania na podstawie niejasnych lub nieprecyzyjnych informacji oraz oferują bardziej elastyczną i realistyczną reprezentację wiedzy i procesów rozumowania. Umożliwiają one modelowanie zjawisk trudnych do opisanie klasycznymi metodami

matematycznymi [6]. Metody rozmyte do tej pory udowodniły swoją przydatność we wspomaganiu rozwiązywania wielu złożonych problemów decyzyjnych [7-10]. Celem artykułu jest przybliżenie pojęcia logiki rozmytej i jej zastosowań w meteorologii. Logika rozmyta ma różne zastosowania w systemach wspomagania decyzji dotyczących analizy pogody [11-14], takich jak modelowanie niepewnych i nieprecyzyjnych danych, co jest powszechne w meteorologii, w celu zapewnienia bardziej elastycznego i podobnego do ludzkiego rozumowania. Może być wykorzystywany do przewidywania zjawisk pogodowych poprzez uwzględnianie danych jakościowych pochodzących z ekspertyz, co usprawnia proces podejmowania decyzji [11,12]. Logika rozmyta ułatwia również łączenie różnych typów danych meteorologicznych, takich jak temperatura, wilgotność i prędkość wiatru, w celu stworzenia kompleksowej analizy. Ponadto może usprawnić krótkoterminową analizę pogody, radząc sobie

z niejednoznacznością i nieliniowością nieodłącznie związanymi z danymi atmosferycznymi. Systemy rozmyte są szczególnie przydatne w regionach o ograniczonych danych historycznych, gdzie tradycyjne modele statystyczne mogą mieć problemy. Istnieją jednak wyzwania związane z zastosowaniem logiki rozmytej do analizy pogody. Jednym z głównych wyzwań jest trudność w określeniu odpowiednich funkcji i zasad członkostwa, które wymagają wiedzy eksperckiej i mogą być subiektywne. Kolejnym wyzwaniem jest możliwość nadmiernego uproszczenia, ponieważ logika rozmyta może nie uchwycić w pełni złożoności i dynamiki systemów pogodowych. Brak zdolności adaptacyjnych tradycyjnych systemów rozmytych oznacza, że mogą one nie działać dobrze, gdy wzorce pogodowe zmieniają się w czasie. Ponadto wydajność obliczeniowa może stanowić problem podczas przetwarzania ogromnych i złożonych danych związanych z analizą pogody. Wreszcie, integracja logiki rozmytej z innymi zaawansowanymi modelami predykcyjnymi, takimi jak uczenie maszynowe, stwarza wyzwania techniczne i koncepcyjne, szczególnie w zakresie zapewnienia spójności i niezawodności.

2. ZBIORY ROZMYTE

Zbiory rozmyte zostały wprowadzone przez Zadeha (1965) w oparciu o założenie, że precyzyjne opisanie wielu sytuacji w świecie rzeczywistym jest praktycznie niemożliwe, a nieprecyzyjnie zdefiniowane "klasy" są ważne w ludzkim myśleniu i języku naturalnym [15]. Teoria mnogości rozmytych umożliwia opisywanie jakościowych, rozmytych pojęć i wiedzy o otaczającym świecie, a także operowanie na wiedzy zawartej w tej teorii, tworząc niezależne pole badań naukowych [16]. Zbiór rozmyty to klasa obiektów o określonym stopniu przynależności. Taki zbiór charakteryzuje się funkcją przynależności, która przypisuje każdemu obiektowi stopień przynależności w zakresie od zera do jedynki [17]. Jednym ze sposobów opisanie zbioru rozmytego A jest podanie jego funkcji przynależności $\mu_A: X \rightarrow [0, 1]$ [18]. Wartość $\mu_A(x)$ jest więc liczbą w przedziale $[0, 1]$ i nazywa się ją stopniem przynależności elementu x do zbioru A. Funkcja członkostwa ma bogaty wybór kształtów i może być opisana za pomocą różnych metod i funkcji matematycznych. Dobór odpowiedniego kształtu i parametrów funkcji członkostwa ma kluczowe znaczenie dla efektywności systemów wykorzystujących zbiory rozmyte. Powszechnie stosowane funkcje przynależności obejmują funkcje trójkątne, funkcje trapezowe, funkcje Gaussa i funkcję przynależności typu

singleton [7]. W tym artykule użyto funkcji trójkątnych i trapezowych:

1. Trójkątna funkcja przynależności

Funkcja ta jest definiowana za pomocą trzech parametrów a, b, c, które określają współrzędne na osi x [19].

$$\mu_F(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x < c \\ 0, & x \geq c \end{cases}$$

2. Trapezoidalna funkcja przynależności

Funkcja ta jest definiowana za pomocą czterech parametrów a, b, c, d, które określają współrzędne na osi x [19].

$$\mu_F(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x < b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c < x < d \\ 0, & x \geq d \end{cases}$$

2.1. Systemy rozmyte

Istnieją dwa główne typy systemów rozmytych, Mamdani [20] i Sugeno [21]. Systemy rozmyte Mamdani i Sugeno dla danego systemu mają taką samą liczbę funkcji wejściowych i wyjściowych oraz te same reguły. Jedyną różnicą między nimi jest sposób, w jaki rozmyte wyjście jest defuzyfikowane [22]. Niniejszy artykuł koncentruje się na wykorzystaniu wnioskowania Mamdani, które jest jedną z najpopularniejszych technik logiki rozmytej, do projektowania modelu analizy pogody.

System Mamdani składa się z reguł IF-THEN, które definiują, w jaki sposób dane wejściowe i wyjściowe są ze sobą powiązane. Każda reguła może używać różnych zestawów rozmytych A i B, które mogą być połączone spójnikami logicznymi AND i OR [20,23].

Zbiór rozmyty, baza reguł rozmytych IF-THEN, zmienne językowe, rozkład możliwości to podstawowe pojęcia systemu logiki rozmytej [24]. Systemy rozmyte radzą sobie z ludzkim rozumowaniem nawet przy wysokim poziomie abstrakcji. System wnioskowania rozmytego powinien być w stanie odtworzyć algorytmicznie ustrukturyzowaną ludzką wiedzę poprzez zakodowanie jej w zestawie reguł IF-THEN. Każda reguła reprezentuje zadanie do wykonania [25].

2.2. Zbiór danych


Model analizy pogody zaprezentowany w pracy (rys. 1) opiera się na danych z Seattle (2012-2015) z bazy Weather

Analysis z Kaggle, zawierającej 1462 rekordy o opadach i warunkach pogodowych. System rozmyty zaprojektowano w Matlabie przy użyciu aplikacji Fuzzy Logic Designer, łącząc logikę rozmytą z technikami sztucznej inteligencji do zarządzania niepewnością danych. Matlab umożliwia tworzenie systemów rozmytych, które skutecznie radzą sobie z nieprecyzyjnymi danymi.

	1	2	3	4	5	6
	date	precipitation	temp_max	temp_min	wind	weather
1	2012-01-01	0	12.8000	5	4.7000	'drizzle'
2	2012-01-02	10.9000	10.6000	2.8000	4.5000	'rain'
3	2012-01-03	0.8000	11.7000	7.2000	2.3000	'rain'
4	2012-01-04	20.3000	12.2000	5.6000	4.7000	'rain'
5	2012-01-05	1.3000	8.9000	2.8000	6.1000	'rain'
6	2012-01-06	2.5000	4.4000	2.2000	2.2000	'rain'
7	2012-01-07	0	7.2000	2.8000	2.3000	'rain'
8	2012-01-08	0	10	2.8000	2	'sun'
9	2012-01-09	4.3000	9.4000	5	3.4000	'rain'
10	2012-01-10	1	6.1000	0.6000	3.4000	'rain'
11	2012-01-11	0	6.1000	-1.1000	5.1000	'sun'
12	2012-01-12	0	6.1000	-1.7000	1.9000	'sun'
13	2012-01-13	0	5	-2.8000	1.3000	'sun'
14	2012-01-14	4.1000	4.4000	0.6000	5.3000	'snow'
15	2012-01-15	5.3000	1.1000	-3.3000	3.2000	'snow'
16	2012-01-16	2.5000	1.7000	-2.8000	5	'snow'

Rys. 1 Fragment danych pogodowych z Seattle z lat 2012-2015.

Etapy systemu analizy pogody przedstawiono na schemacie blokowym (rys. 2) w celu utworzenia poniższego modelu analizy pogody.




Rys. 2 - Schemat blokowy do analizy pogody

3. MATERIAŁY I METODY


Model analizy warunków atmosferycznych oparty na logice rozmytej wyróżnia się zdolnością do bardziej precyzyjnego odwzorowywania rzeczywistości oraz uwzględniania subiektywnych odczuć. Dzięki wykorzystaniu stopni przynależności, system pozwala na uchwycenie zmienności danych bez konieczności ich normalizacji, co eliminuje ograniczenia wynikające z narzuconych zakresów liczbowych. Takie podejście umożliwia analizę danych w sposób bardziej naturalny i zgodny z dynamiczną naturą warunków atmosferycznych.

Zbiory rozmyte w modelu są definiowane w sposób subiektywny, co stanowi jego istotną zaletę. Elastyczność tego podejścia pozwala na dostosowanie systemu do indywidualnych preferencji i doświadczeń. Przykładowo, zakres "gorąco" może być różnie interpretowany w zależności od osoby – dla jednej będzie oznaczał temperatury powyżej 30°C, podczas gdy dla innej może to być już 25°C. Taka różnorodność w definiowaniu pojęć nie jest błędem, lecz świadomym elementem modelu, który uwzględnia różnice w percepcji i reakcjach ludzi na te same warunki pogodowe [26]. Dzięki tej subiektywności model nie narzuca sztywnych granic ani uniwersalnych wartości, co sprawia, że lepiej oddaje złożoność i zmienność zjawisk atmosferycznych. Takie podejście umożliwia również bardziej spersonalizowaną interpretację wyników, co jest szczególnie istotne w kontekście prognozowania pogody, gdzie preferencje i oczekiwania ludzi mogą się znacznie różnić. Elastyczność logiki rozmytej pozwala także na lepsze uwzględnienie złożonego charakteru zmian atmosferycznych, oferując narzędzie, które nie tylko analizuje dane, ale również dostosowuje się do ich dynamiki. To sprawia, że system ten staje się nie tylko bardziej funkcjonalny, ale również bardziej intuicyjny, odpowiadając na potrzeby użytkowników i odzwierciedlając ich różnorodne doświadczenia i spojrzenia na otaczający świat [26-28].


Model zawiera trzy zmienne wejściowe (temperatura maksymalna (rys.3), temperatura minimalna (rys. 4), wiatr (rys. 5)) oraz jedną zmienną wyjściową (opady (rys.6)).




Rys. 3 - Zmienna wejściowa temp.max



Rys. 4 – Zmienna wejściowa temp.min



Rys. 5 – Zmienna wejściowa wind



Rys. 6 – Zmienna wyjściowa precipitation

W temperaturze maksymalnej zdefiniowano zmienną „cold”, która reprezentuje poziom chłodu w oparciu o minimalną (T_{min}) i maksymalną (T_{max}) temperaturę w danym zakresie, według wzoru:

$$cold = (T_{min} - 20\% (T_{max} - T_{min})).$$

Podobnie, zdefiniowano zmienną „hot” na podstawie wzoru:

$$hot = (T_{max} - 20\% (T_{min} - T_{max})).$$

Te wartości użyto do zdefiniowania trapezoidalnych funkcji dla zimnych, umiarkowanych i gorących temperatur w przedziale $[-9, 43]$. Stopień przynależności dla wartości lingwistycznych temp_max jest obliczany odpowiednio:

$$\mu_{cold}(x; -9, -9, 5, 10) = \begin{cases} 1, & x \leq 5 \\ \frac{10-x}{5}, & 5 < x < 10 \\ 0, & x \geq 10 \end{cases}$$

$$\mu_{moderate}(x; 8, 15, 22, 29) = \begin{cases} \frac{x-8}{7}, & 8 < x < 15 \\ 1, & 15 \leq x \leq 22 \\ \frac{29-x}{7}, & 22 < x < 29 \\ 0, & x \geq 29 \end{cases}$$

$$\mu_{hot}(x; 25, 30, 43, 43) = \begin{cases} \frac{x-25}{5}, & 25 < x < 30 \\ 1, & x \geq 30 \end{cases}$$

W temperaturze minimalnej zdefiniowano zmienną „very.cold” w oparciu o minimalną (T_{min}) i maksymalną (T_{max}) temperaturę w danym zakresie, według następującego wzoru:

$$very.cold = (T_{min} - 20\% (T_{max} - T_{min})).$$

Podobnie, zdefiniowano zmienną „moderate” na podstawie wzoru:

$$moderate = (T_{max} - 20\% (T_{min} - T_{max})).$$

Te wartości użyto do zdefiniowania trapezoidalnych funkcji dla bardzo zimnych, zimnych i umiarkowanych temperatur w przedziale $[-12, 23]$. Stopień przynależności dla wartości lingwistycznych temp_min jest obliczany odpowiednio:

$$\mu_{very.cold}(x; -12, -12, 0, 5) = \begin{cases} 1, & x \leq 0 \\ \frac{5-x}{5}, & 0 < x < 5 \\ 0, & x \geq 5 \end{cases}$$

$$\mu_{cold}(x; -1.6, 4, 8, 12) = \begin{cases} \frac{x-(-1.6)}{5.6}, & -1.6 < x < 4 \\ 1, & 4 \leq x \leq 8 \\ \frac{12-x}{4}, & 8 < x < 12 \\ 0, & x \geq 12 \end{cases}$$

$$\mu_{moderate}(x; 8, 15, 23, 23) = \begin{cases} \frac{x-8}{7}, & 8 < x < 15 \\ 1, & x \geq 15 \end{cases}$$

We wietrze zdefiniowano zmienną „calm” w oparciu o minimalną (W_{min}) i maksymalną (W_{max}) wartość w danym zakresie, według wzoru:

$$calm = (W_{min} - 20\% (W_{max} - W_{min})).$$

Podobnie, zdefiniowano zmienną „windy” na podstawie wzoru:

$$windy = (W_{max} - 20\% (W_{min} - W_{max})).$$

Te wartości użyto do zdefiniowania trapezoidalnych funkcji dla spokojnego, lekko wietrznego i wietrznego wiatru w przedziale $[-1, 11]$. Stopień przynależności dla wartości lingwistycznych wind jest obliczany odpowiednio:

$$\mu_{calm}(x; -1, -1, 1, 3) = \begin{cases} 1, & x \leq 1 \\ \frac{3-x}{2}, & 1 < x < 3 \\ 0, & x \geq 3 \end{cases}$$

$$\mu_{breezy}(x; 2, 3, 6, 7.5) = \begin{cases} \frac{x-2}{1}, & 2 < x < 3 \\ 1, & 3 \leq x \leq 6 \\ \frac{7.5-x}{1.5}, & 6 < x < 7.5 \\ 0, & x \geq 7.5 \end{cases}$$

$$\mu_{windy}(x; 6, 8, 11, 11) = \begin{cases} \frac{x-6}{2}, & 6 < x < 8 \\ 1, & x \geq 8 \end{cases}$$

Zmienna wyjściowa „opady” jest przedstawiona za pomocą funkcji trójkątnej z pięcioma poziomami: very.low, low, normal, high, very.high. Funkcja jest zdefiniowana w przedziale $[0, 56]$, który został podzielony na pięć równych zakresów. Stopień przynależności dla wartości lingwistycznych opadów jest obliczany odpowiednim wzorem:

$$\mu_{\text{very.low}}(x; 0, 7, 14) = \begin{cases} 0, & x \leq 0 \\ \frac{x}{7}, & 0 < x < 7 \\ \frac{14-x}{7}, & 7 < x < 14 \\ 0, & x \geq 14 \end{cases}$$

$$\mu_{\text{low}}(x; 10.5, 17.5, 24.5) = \begin{cases} 0, & x \leq 10.5 \\ \frac{x-10.5}{7}, & 10.5 < x < 17.5 \\ \frac{24.5-x}{7}, & 17.5 < x < 24.5 \\ 0, & x \geq 24.5 \end{cases}$$

$$\mu_{\text{normal}}(x; 21, 28, 35) = \begin{cases} 0, & x \leq 21 \\ \frac{x-21}{7}, & 21 < x < 28 \\ \frac{35-x}{7}, & 28 < x < 35 \\ 0, & x \geq 35 \end{cases}$$

$$\mu_{\text{high}}(x; 31.5, 38.5, 45.5) = \begin{cases} 0, & x \leq 31.5 \\ \frac{x-31.5}{7}, & 31.5 < x < 38.5 \\ \frac{45.5-x}{7}, & 38.5 < x < 45.5 \\ 0, & x \geq 45.5 \end{cases}$$

$$\mu_{\text{very.high}}(x; 42, 49, 56) = \begin{cases} 0, & x \leq 42 \\ \frac{x-42}{7}, & 42 < x < 49 \\ \frac{56-x}{7}, & 49 < x < 56 \\ 0, & x \geq 56 \end{cases}$$


Baza reguł systemu opiera się na wnioskowaniu Mamdaniego z funkcją IF-THEN i operatorem AND. 35 reguł przetwarza dane wejściowe, generując rozmyte dane wyjściowe dotyczące opadów. Na podstawie wartości danych wejściowych wiatru, temperatury minimalnej i maksymalnej oraz danych wyjściowych opadów stworzono trzydzieści pięć reguł, zgodnie z założeniami projektu i danymi pogodowymi Seattle z lat 2012-2015. Zasady są następujące:

1. If (temp.max is moderate) and (temp.min is moderate) and (wind is windy) then (precipitation is very.high)
2. If (temp.max is moderate) and (temp.min is cold) and (wind is breezy) then (precipitation is very.high)
3. If (temp.max is moderate) and (temp.min is cold) and (wind is windy) then (precipitation is very.high)
4. If (temp.max is moderate) and (temp.min is moderate) and (wind is breezy) then (precipitation is very.high)
5. If (temp.max is moderate) and (temp.min is moderate) and (wind is breezy) then (precipitation is high)
6. If (temp.max is moderate) and (temp.min is cold) and (wind is breezy) then (precipitation is high)
7. If (temp.max is moderate) and (temp.min is cold) and (wind is windy) then (precipitation is high)


8. If (temp.max is moderate) and (temp.min is cold) and (wind is calm) then (precipitation is high)
9. If (temp.max is moderate) and (temp.min is cold) and (wind is breezy) then (precipitation is normal)
10. If (temp.max is cold) and (temp.min is cold) and (wind is breezy) then (precipitation is normal)
11. If (temp.max is cold) and (temp.min is cold) and (wind is windy) then (precipitation is normal)
12. If (temp.max is moderate) and (temp.min is moderate) and (wind is breezy) then (precipitation is normal)
13. If (temp.max is moderate) and (temp.min is moderate) and (wind is windy) then (precipitation is normal)
14. If (temp.max is moderate) and (temp.min is moderate) and (wind is calm) then (precipitation is normal)
15. If (temp.max is moderate) and (temp.min is cold) and (wind is calm) then (precipitation is normal)
16. If (temp.max is moderate) and (temp.min is cold) and (wind is windy) then (precipitation is normal)
17. If (temp.max is cold) and (temp.min is cold) and (wind is breezy) then (precipitation is low)
18. If (temp.max is cold) and (temp.min is cold) and (wind is calm) then (precipitation is low)
19. If (temp.max is moderate) and (temp.min is cold) and (wind is windy) then (precipitation is low)
20. If (temp.max is cold) and (temp.min is cold) and (wind is windy) then (precipitation is low)
21. If (temp.max is moderate) and (temp.min is moderate) and (wind is windy) then (precipitation is low)
22. If (temp.max is moderate) and (temp.min is cold) and (wind is breezy) then (precipitation is low)
23. If (temp.max is moderate) and (temp.min is moderate) and (wind is calm) then (precipitation is low)
24. If (temp.max is moderate) and (temp.min is cold) and (wind is calm) then (precipitation is low)
25. If (temp.max is cold) and (temp.min is very.cold) and (wind is calm) then (precipitation is very.low)
26. If (temp.max is cold) and (temp.min is very.cold) and (wind is breezy) then (precipitation is very.low)
27. If (temp.max is cold) and (temp.min is cold) and (wind is breezy) then (precipitation is very.low)
28. If (temp.max is cold) and (temp.min is cold) and (wind is calm) then (precipitation is very.low)
29. If (temp.max is moderate) and (temp.min is cold) and (wind is breezy) then (precipitation is very.low)
30. If (temp.max is moderate) and (temp.min is very.cold) and (wind is calm) then (precipitation is very.low)
31. If (temp.max is moderate) and (temp.min is cold) and (wind is calm) then (precipitation is very.low)
32. If (temp.max is moderate) and (temp.min is moderate) and (wind is calm) then (precipitation is very.low)

33. If (temp.max is moderate) and (temp.min is moderate) and (wind is breezy) then (precipitation is very.low)
 34. If (temp.max is hot) and (temp.min is moderate) and (wind is breezy) then (precipitation is very.low)
 35. If (temp.max is hot) and (temp.min is moderate) and (wind is windy) then (precipitation is very.low)

Wyniki analizy pogody można przeprowadzić za pomocą wykresów powierzchniowych 3D, jak pokazano na rysunkach 7 i 8. Na rysunku 7 można zauważyć, że wraz ze wzrostem wiatru i maksymalnej temperatury wzrasta również ilość opadów. Na rysunku 8 widać, że opady gwałtownie rosną wraz ze wzrostem wiatru, szczególnie przy niskich wartościach temperatury minimalnej. Wyraźnie widać, że przy najniższej minimalnej temperaturze i wietrze opady są bliskie zeru. Podobny schemat widać na wykresie 7, gdzie przy najniższych wartościach maksymalnej temperatury i wiatru opady są również minimalne. Na podstawie analizy obu wykresów można stwierdzić, że kluczowym czynnikiem wpływającym na ilość opadów jest wiatr, ponieważ wraz ze wzrostem wiatru opady stają się bardziej intensywne.



Rys. 7 - Wynik 3D na podstawie danych wejściowych



Rys. 8 - Wynik 3D na podstawie danych wejściowych

Model przetestowano na 30 zestawach danych testowych, a jego wyniki porównano z rzeczywistymi opadami (tab. 1). Tabela 1. Wyniki przeprowadzonego testu

Temp.max	Temp.min	Wind	Actual precipitation	Results
35	17.2	3.3	0	7.0
33.3	17.8	3.4	0	7.0
18.3	15.0	5.2	30.5	30.3721
5.6	2.8	4.3	27.4	17.5052
8.9	4.4	5.1	18.5	27.0319
6.7	3.9	6.0	21.8	17.5076
13.3	9.4	6.5	33.5	28.0
8.9	2.2	4.1	22.4	27.0319
13.3	6.7	8.0	29.5	33.2407
21.1	13.3	4.7	28.7	30.3559
1.1	-3.3	3.2	5.3	7.0
1.7	-2.8	5.0	2.5	7.0
11.1	10.0	7.2	30.0	30.3941
31.1	14.4	2.5	0	7.0
8.3	5.0	3.9	39.1	19.8240
-1.1	-2.8	1.6	15.2	7.0
6.7	-0.6	4.2	3.6	13.2611
8.3	0.6	6.2	19.3	19.8240
13.9	11.7	1.9	15.7	18.6014
33.9	16.7	3.7	0	7.0
30.6	15.0	3.0	0	7.0
30.6	15.0	2.8	0	7.0
31.1	16.7	4.7	0	7.0
32.2	13.3	3.1	0	7.0
17.8	6.7	2.0	20.8	22.7593
15.0	12.2	2.8	34.5	29.8978
9.4	6.1	2.4	32	28.0
8.3	7.2	6.2	19.6	19.8240
7.2	0.6	3.7	13.2	16.4979
6.7	-1.7	3.0	4.1	7.0

Jakość oceniono za pomocą MSE i R^2 . Średni błąd kwadratowy (MSE) to średnia kwadratowa różnica między wartościami obserwowanymi w badaniu statystycznym a wartościami przewidywanymi przez model. Porównując obserwacje z wartościami przewidywanymi, konieczne jest podniesienie różnic do kwadratu, ponieważ niektóre wartości danych będą większe niż analiza, podczas gdy inne będą mniejsze. Ponieważ istnieje równe prawdopodobieństwo, że obserwacje będą większe lub mniejsze niż przewidywane wartości, różnice w przeciwnym razie sumowałyby się do zera. Kwadratowanie tych różnic zapobiega temu zjawisku [29]. Współczynnik determinacji (R^2) jest miarą stosowaną do oceny zdolności modelu do przewidywania lub wyjaśniania wyniku w warunkach regresji liniowej. W szczególności R^2 reprezentuje część wariancji zmiennej zależnej (Y), która jest przewidywana lub wyjaśniana przez regresję liniową i zmienną predykcijną (X, znaną również jako zmienna niezależna) [30]. W prezentowanych badaniach MSE wynosi 42,4689, a R^2 0,74963, co wskazuje, że model jest użyteczny, choć istnieje potencjał do dalszej optymalizacji w celu poprawy jakości analizy pogody.

Wynik ten oznacza, że model jest w stanie rozpoznać pogodę z dokładnością około 75%, co jest całkiem dobre, ale nie idealne. Model ma szczególne trudności z analizą silniejszych opadów deszczu, co może być związane z faktem, że obfite opady deszczu są rzadkością na badanym obszarze. Takie zjawiska są trudniejsze do przewidzenia ze względu na ich nieregularność i mniejszą dostępność danych historycznych. W celu ulepszenia modelu można rozważyć włączenie dodatkowych zmiennych lub rozszerzenie zbioru danych, zwłaszcza o te dotyczące bardziej ekstremalnych warunków pogodowych. Takie działania mogłyby zwiększyć dokładność analizy, zwłaszcza w przypadku bardziej nietypowych zjawisk.

4. Dyskusja

Inspiracją do napisania artykułu była rosnąca potrzeba prognozowania pogody, istotna dla bezpieczeństwa, planowania, rolnictwa, transportu, zdrowia publicznego, turystyki i zarządzania energią. W badaniu wykorzystano dane meteorologiczne z rejonu Seattle oraz trzy zmienne wejściowe: temperaturę minimalną, maksymalną i prędkość wiatru, by przewidzieć opady. Stworzono model oparty na logice rozmytej z funkcjami przynależności (trapezoidalnymi i trójkątnymi) oraz metodą Mamdaniego, co zwiększyło dokładność przewidywań. Wyniki potwierdzają skuteczność tego podejścia w analizie pogody, wskazując na przewagę logiki rozmytej nad tradycyjnymi metodami w systemach wspomagania decyzji.

4.1. Ograniczenia aktualnie prowadzonych badań

Logika rozmyta, choć przydatna do radzenia sobie z niepewnością w systemach wspomagania decyzji, ma kilka ograniczeń w przewidywaniu warunków pogodowych. Dokładność analizy może być zagrożona przez subiektywny charakter definiowania zbiorów rozmytych i funkcji członkostwa. Logika rozmyta nie radzi sobie z danymi na dużą skalę i dynamicznymi, nieliniowymi interakcjami typowymi dla systemów pogodowych, co może prowadzić do zbyt uproszczonych modeli [31]. Logika rozmyta nie jest w stanie uczyć się na podstawie nowych danych, ponieważ opiera się na wstępnie zdefiniowanych regułach, które nie dostosowują się w czasie. Interpretowalność systemów rozmytych może być wyzwaniem w przypadku złożonych reguł, co utrudnia zrozumienie lub udoskonalenie modelu [32]. Logika rozmyta może nie uwzględniać odpowiednio ekstremalnych zjawisk pogodowych, ponieważ ma tendencję do wygładzania danych, potencjalnie zaniżając ryzyko. Wydajność obliczeniowa logiki rozmytej może stanowić

problem podczas przetwarzania danych wielowymiarowych, często związanych z analizą pogody. Integracja logiki rozmytej z innymi modelami predykcyjnymi, takimi jak uczenie maszynowe, może być złożona i wymagać znacznego dostrojenia [33]. Logika rozmyta może nie działać dobrze w bardzo chaotycznych systemach, takich jak pogoda, gdzie małe zmiany mogą prowadzić do bardzo różnych wyników. Brak ustandaryzowanych metod konstruowania systemów rozmytych może prowadzić do niespójności w różnych implementacjach [34]. Logika rozmyta może mieć problemy ze skalowalnością, zwłaszcza gdy do systemu dodaje się więcej zmiennych i reguł [35].

4.2. Kierunki dalszych badań

Przyszłe badania nad logiką rozmytą w analizie pogody mogą koncentrować się na adaptacyjnych metodach projektowania funkcji przynależności z wykorzystaniem uczenia maszynowego, integracji z modelami głębokiego uczenia i sieciami bayesowskimi w celu lepszego radzenia sobie z niepewnością [36,37]. Ważne kierunki to także uwzględnianie ekstremalnych zjawisk pogodowych, optymalizacja wydajności obliczeniowej (np. poprzez przetwarzanie równoległe), poprawa interpretowalności modeli oraz integracja teorii chaosu i obliczeń kwantowych. Opracowanie ujednoliconej struktury dla systemów logiki rozmytej i mechanizmów informacji zwrotnej mogłoby zwiększyć spójność i efektywność tych narzędzi [38-41].

5. Wnioski

Model analizy pogody oparty na logice rozmytej wykorzystuje trzy kluczowe zmienne wejściowe: temperaturę maksymalną, temperaturę minimalną i prędkość wiatru. Na tej podstawie, przy użyciu 35 reguł, generowane są prognozy dotyczące opadów, klasyfikowanych jako bardzo niskie, niskie, normalne, wysokie i bardzo wysokie. Opracowanie takiego systemu wymaga uwzględnienia wielu czynników, które mają wpływ na dokładność analizy, ponieważ prognozowanie pogody, nawet z wykorzystaniem zaawansowanych technologii, pozostaje wyzwaniem ze względu na dynamiczny charakter klimatu.

Choć opracowany model dostarcza wiarygodnych analiz, uzyskanie pełnej precyzji jest trudne ze względu na zmienność i złożoność zjawisk atmosferycznych. Konieczne jest zatem ciągle doskonalenie modeli i narzędzi analitycznych, które mogą dostarczyć lepszych wyników. W przyszłości istotnym krokiem będzie rozszerzenie modeli o dodatkowe czynniki, takie jak zmieniające się wzorce klimatyczne, ekstremalne zjawiska pogodowe, anomalie

sezonowe, wilgotność powietrza czy ciśnienie atmosferyczne. Uwzględnienie takich zmiennych mogłoby znacząco poprawić dokładność prognoz zarówno w perspektywie krótkoterminowej, jak i długoterminowej. Zaawansowane modele prognozowania mogłyby również wspierać analizy związane z długoterminowym wpływem zmian klimatycznych na przyszłe warunki pogodowe. Rozwój technologii, takich jak sztuczna inteligencja czy uczenie maszynowe, może przyczynić się do automatyzacji i optymalizacji procesów analitycznych, umożliwiając generowanie bardziej kompleksowych i spersonalizowanych prognoz.

Rozbudowane systemy analizy pogody znajdują zastosowanie nie tylko w prognozowaniu atmosferycznym, ale także w szerokim spektrum dziedzin. Mogą wspierać zarządzanie energią odnawialną poprzez precyzyjne przewidywanie warunków pogodowych, wpływać na planowanie przestrzenne czy rozwijać mechanizmy wczesnego ostrzegania przed klęskami żywiołowymi, takimi jak powodzie czy huragany. W ten sposób prognozowanie pogody staje się kluczowym narzędziem w podejmowaniu decyzji strategicznych, przynosząc korzyści w wielu aspektach życia społecznego i gospodarczego.

Literatura

- [1] Müller, A.; Gillard, M.; Pagh Nielsen, K.; Piotrowski, Z. Batch 2: Definition of novel Weather & Climate Dwarfs. *CoRR* **2019**, abs/1908.07040
- [2] Li, M.; Liu, Y.; Ji, Z.; Niu, D.; Zhang, H. Daily Load Forecasting of Electric Power Manufacturing Industry Considering Disaster Weather Recognition Under the Deep Learning. *CCIS* **2021**, 243-249
- [3] Lionetti, S.; Pfäffli, D.; Pouly, M.; von der Brück, T.; Wegelin, P. Tourism Forecast with Weather, Event, and Cross-industry Data. *ICAART* **2021**, 1097-1104
- [4] Sripada, S.; Burnett, N.; Turner, R.; Mastin, J.; Evans, E. A Case Study: NLG meeting Weather Industry Demand for Quality and Quantity of Textual Weather Forecasts. *INLG* **2014**, 1-5
- [5] Rahman, M.A. Improvement of Rainfall Prediction Model by Using Fuzzy Logic. *American Journal of Climate Change*, **2020**, 9, 391-399
- [6] Małolepsza, O. Metody adaptacji systemów wiedzy opartej na zbiorach rozmytych. *Studia i Materiały Informatyki Stosowanej* **2023**, 15, 1, 11-20
- [7] Prokopowicz, P.; Czerniak, J.; Mikołajewski, D.; Apiecionek, Ł.; Ślęzak, D., Eds.; Theory and Applications of Ordered Fuzzy Numbers; Studies in Fuzziness and Soft Computing; Springer: Cham, Switzerland, 2017; Volume 356
- [8] Kozielski, M.; Prokopowicz, P.; Mikołajewski, D. Aggregators Used in Fuzzy Control—A Review. *Electronics* **2024**, 13, 3251. <https://doi.org/10.3390/electronics13163251>.
- [9] Mikołajewska, E.; Prokopowicz, P.; Mikołajewski, D. Computational gait analysis using fuzzy logic for everyday clinical purposes - preliminary findings. *Bio-Algorithms and Med-Systems* **2017**, 13, 1, 37-42.
- [10] Prokopowicz, P.; Mikołajewski, D.; Mikołajewska, E.; Kotlarz, P. Fuzzy System as an Assessment Tool for Analysis of the Health-Related Quality of Life for the People After Stroke. 16th International Conference on Artificial Intelligence and Soft Computing (ICAISC) 2017, PT I, 10245, pp.710-721.
- [11] Peláez-Rodríguez, C.; Pérez-Aracil, J.; Madalin Marina, C.; Prieto-Godino, L.; Casanova-Mateo, C.; Gutiérrez, P. A.; Salcedo-Sanz, S. A general explicable forecasting framework for weather events based on ordinal classification and inductive rules combined with fuzzy logic. *Knowl. Based Syst.* **2024**, 291, 111556.
- [12] Valverde, M.C.; Araujo, E.; de Campos Velho, H.F. Neural network and fuzzy logic statistical downscaling of atmospheric circulation-type specific weather pattern for rainfall forecasting. *Appl. Soft Comput.* **2014**, 22, 681-694.
- [13] Bressane, A.; Garcia, A.J.d.S.; Castro, M.V.d.; Xerfan, S.D.; Ruas, G.; Negri, R.G. Fuzzy Machine Learning Applications in Environmental Engineering: Does the Ability to Deal with Uncertainty Really Matter? *Sustainability* **2024**, 16, 4525. <https://doi.org/10.3390/su16114525>
- [14] Ćesić, M.; Rogulj, K.; Kilić Pamuković, J.; Krtalić, A. A Systematic Review on Fuzzy Decision Support Systems and Multi-Criteria Analysis in Urban Heat Island Management. *Energies* **2024**, 17, 2013. <https://doi.org/10.3390/en17092013>
- [15] Singpurwalla, N.D.; Booker, J.M. Membership Functions and Probability Measures of Fuzzy Sets. *Journal of the American Statistical Association*, **2004**, 99, 467, 867–877. doi:10.1198/016214504000001196
- [16] Trach, Y.; Trach, R.; Kuznietsov, P.; Pryshchepa, A.; Biedunkova, O.; Kiersnowska, A.; Statnyk, I. Predicting the Influence of Ammonium Toxicity Levels in Water Using Fuzzy Logic and ANN Models. *Sustainability* **2024**, 16, 5835. <https://doi.org/10.3390/su16145835>
- [17] Zadeh, L.A. Fuzzy Sets. *Information and Control* **1965**, 8, 338-353.
- [18] Zadeh, L.A.; Aliev, R.A. Fuzzy Logic Theory And Applications: Part I And Part II. World Scientific, 2018.

- [19] Azam, M.H.; Hasan, M.H.; Hassan, S.; Abdulkadir, S.J. Fuzzy Type-1 Triangular Membership Function Approximation Using Fuzzy C-Means, In Proceedings of the 2020 International Conference on Computational Intelligence (ICCI), 2020.
- [20] Mamdani, E. H.; Assilian, S. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, **1975**, 7, 1, 1–13. doi:10.1016/s0020-7373(75)80002-2
- [21] Takagi, T.; Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, **1985**, SMC-15, 1, 116–132. doi:10.1109/tsmc.1985.6313399
- [22] Egaji, O.; Griffiths, A.; Hasan, M.; Yu, H. A comparison of Mamdani and Sugeno fuzzy based packet scheduler for MANET with a realistic wireless propagation model. *International Journal of Automation and Computing* **2015**, 12, 1-13. 10.1007/s11633-014-0861-y.
- [23] Izquierdo, S.; Izquierdo, L.R. Mamdani Fuzzy Systems for Modelling and Simulation: A Critical Assessment. *Journal of Artificial Societies and Social Simulation* **2018**, 21, 3, 2, DOI: 10.18564/jasss.3660.
- [24] Singla, M.K.; Kaur, H. D.; Nijhawan, P. Rain Prediction using Fuzzy Logic. *International Journal of Engineering and Advanced Technology*, **2019**, 9, 1
- [25] Dualibe, C.; Verleysen, M.; Jespers, P.G.A. Design of Analog Fuzzy Logic Controllers in CMOS Technologies: Implementation, Test and Application. Springer, 2003
- [26] Menyhárt, J.; Kalmár, F. Investigation of Thermal Comfort Responses with Fuzzy Logic. *Energies* **2019**, 12, 1792. <https://doi.org/10.3390/en12091792>
- [27] Agboola, A. H.; Gabriel, A. J.; Aliyu, E. O., & Alese, B. K. Development of a Fuzzy Logic Based Rainfall Prediction Model. *International Journal of Engineering and Technology*, **2013**, 3, 427-435. <https://doi.org/10.5751/ES-05896-180422>
- [28] Zhao, Q.; Lian, Z.; Lai, D. Thermal comfort models and their developments: A review. *Energy Built Environ.* **2021**, 2, 21–33
- [29] <https://www.britannica.com/science/mean-squared-error>
- [30] <https://www.britannica.com/science/coefficient-of-determination>
- [31] Šuljug, J.; Spišić, J.; Grgić, K.; Žagar, D. A Comparative Study of Machine Learning Models for Predicting Meteorological Data in Agricultural Applications. *Electronics* **2024**, 13, 3284. <https://doi.org/10.3390/electronics13163284>.
- [32] Yona, A.; Senjyu, T.; Funabashi, T.; Mandal, P.; Kim, C.-H. Optimizing Re-planning Operation for Smart House Applying Solar Radiation Forecasting. *Appl. Sci.* **2014**, 4, 366-379. <https://doi.org/10.3390/app4030366>.
- [33] Rojek, I.; Mikołajewski, D.; Mroziński, A.; Macko, M. Green Energy Management in Manufacturing Based on Demand Prediction by Artificial Intelligence—A Review. *Electronics* **2024**, 13, 3338. <https://doi.org/10.3390/electronics13163338>.
- [34] Lu, J.; Bai, D.; Zhang, N.; Yu, T.; Zhang, X. Fuzzy Case-Based Reasoning System. *Appl. Sci.* **2016**, 6, 189. <https://doi.org/10.3390/app6070189>.
- [35] Zhang, X.; Ye, J.; Ma, S.; Gao, L.; Huang, H.; Xie, Q. MISAO: Ultra-Short-Term Photovoltaic Power Forecasting with Multi-Strategy Improved Snow Ablation Optimizer. *Appl. Sci.* **2024**, 14, 7297. <https://doi.org/10.3390/app14167297>.
- [36] Han, M.; Leeuwenburg, T.; Murphy, B. Site-Specific Deterministic Temperature and Dew Point Forecasts with Explainable and Reliable Machine Learning. *Appl. Sci.* **2024**, 14, 6314. <https://doi.org/10.3390/app14146314>.
- [37] Zou, M.; Gu, J.; Fang, D.; Harrison, G.P.; Djokic, S.Z.; Wang, X.; Zhang, Ch. Comparison of Three Methods for a Weather Based Day-Ahead Load Forecasting. *ISGT Europe* **2019**, 1-5
- [38] Teixeira, R.; Cerveira, A.; Pires, E.J.S.; Baptista, J. Enhancing Weather Forecasting Integrating LSTM and GA. *Appl. Sci.* **2024**, 14, 5769. <https://doi.org/10.3390/app14135769>.
- [39] Hatipoğlu, I.; Tosun, Ö. Predictive Modeling of Flight Delays at an Airport Using Machine Learning Methods. *Appl. Sci.* **2024**, 14, 5472. <https://doi.org/10.3390/app14135472>.
- [40] Son, L.H.; Thong, P.H. Some novel hybrid forecast methods based on picture fuzzy clustering for weather nowcasting from satellite image sequences. *Appl. Intell.* **2017**, 46, 1, 1-15.
- [41] Hu, F.; Zhang, L.; Wang, J. A Hybrid Convolutional–Long Short-Term Memory–Attention Framework for Short-Term Photovoltaic Power Forecasting, Incorporating Data from Neighboring Stations. *Appl. Sci.* **2024**, 14, 5189. <https://doi.org/10.3390/app14125189>.