



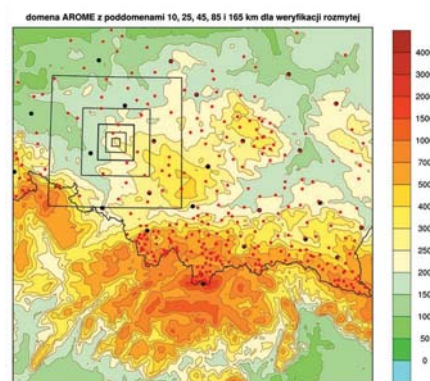
Rozwój metod prognozowania numerycznego o podwyższonej rozdzielczości przestrzennej

Weryfikacja mezoskalowa – metody weryfikacji rozmytej

Wykorzystując metody rozmyte opracowano system weryfikacji i porównania trafności prognoz wysokiej rozdzielczości. Przygotowane narzędzie wykorzystano do analizy prognoz opadu modeli mezoskalowych ALADIN i AROME. Zastosowana metoda rozmyta pozwoliła na ocenę zgodności prognozy z obserwacjami z uwzględnieniem sąsiedztwa korespondujących węzłów sieci obserwacyjnej i siatki modelu. W tego typu podejściu stosowane są dwie strategie: „pojedyncza obserwacja – prognoza w sąsiedztwie” (SO-NF) oraz „obserwacja w sąsiedztwie – prognoza w sąsiedztwie” (NO-NF). Określenie „pojedyncza” odnosi się do jednej stacji obserwacyjnej, „sąsiedztwo” dotyczy kilku węzłów siatki lub stacji obserwacyjnych. Ze względu na różnorodność reguł mogących służyć określeniu zgodności prognozy z obserwacjami powstało kilka koncepcji zastosowania weryfikacji rozmytej prognozy pogody.

Strategia porównania i model decyzyjny poszczególnych (wybranych) metod:


- ▷ Upscaling (NO-NF) - dobra prognoza przypomina obserwacje uśrednione do większej skali
- ▷ Minimum coverage (NO-NF) – dobra prognoza przewiduje zdarzenie na minimalnym ułamku obszaru zainteresowania
- ▷ Multi-event contingency table (SO-NF) – dobra prognoza przewiduje przynajmniej jedno zdarzenie blisko zdarzenia obserwowanego
- ▷ Fuzzy logic (NO-NF) – dobra prognoza jest bardziej trafna niż nietrafna w obszarze zainteresowania
- ▷ Fractions Skill Score (NO-NF) – w dobrej prognozie częstość przewidywana wystąpienia zdarzenia jest podobna częstości zdarzeń obserwowanych
- ▷ Pragmatic approach (SO-NF) – dobra prognoza przewiduje wystąpienie zjawiska jak też niewystąpienie zjawiska z dużym prawdopodobieństwem
- ▷ Intensity-scale (NO-NF) – struktura dobrej prognozy jest bardziej dokładna niż przypadkowy układ obserwacji
- ▷ Practically perfect hindcast (SO-NF) – dobra prognoza przypomina taką jaką dałby synoptyk mający doskonałą wiedzę o zjawisku
- ▷ Conditional square root of RPS (SO-NF) – dobra prognoza odznacza się wysokim prawdopodobieństwem dopasowania do wartości obserwowanych
- ▷ Area-related RMSE (NO-NF) – dobra prognoza wykazuje podobieństwo rozkładu i natężenia z obserwacjami.



Obszar badań z naniesionymi przykładowymi sąsiedztwami stacji synoptycznych (oknami) (kwadraty odpowiadają skalom: 10 km, 25 km, 45 km, 85 km, 165 km), stacjami synoptycznymi (czarne punkty) i automatycznymi stacjami synoptycznymi ATS (czerwone punkty)

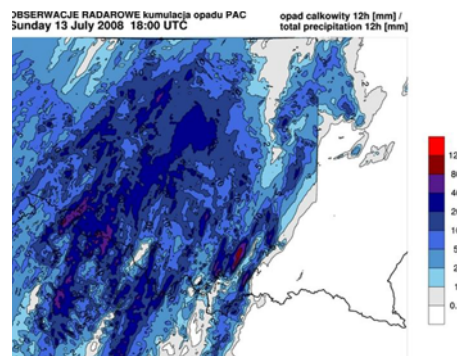

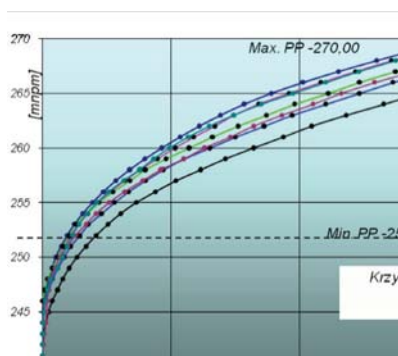
	POD	Minimum	coverage					
165km	0.47	0	0.35	0	0	0.04	0	
85km	0.4	0	0.43	0.08	0.16	0.31	0	
45km	0.45	0.09	0.34	0.06	0.14	0.3	0	
25km	0.47	0.13	0.3	0.16	0.2	0.32	0	
15km	0.53	0.15	0.32	0.19	0.29	0.39	0	
10km	0.5	0.13	0.28	0.22	0.23	0.35	0	
5km	0.23	0.04	0.13	0.03	0.06	0.16	0	
1km	0	0	0	0	0	0	0	

	POD	Minimum	coverage					
165km	0.98	0	0	0	0	0	0	
85km	0.92	0	0	0	0.01	0.16	0	
45km	0.83	0	0	0	0.11	0.27	0	
25km	0.78	0	0.05	0.01	0.09	0.28	0	
15km	0.79	0.01	0.06	0.01	0.07	0.36	0	
10km	0.81	0.01	0.03	0.04	0.08	0.33	0	
5km	0.78	0.09	0.05	0.08	0.18	0.33	0	
1km	0.29	0	0.02	0	0.07	0.14	0	



Przykładowa krzywa ROC dla miesięcznego zestawienia 24-godzinnych sum opadów ze stacji synoptycznych z wynikami modelu ALADIN. Prezentuje wyniki weryfikacji metodą Multi-event

Przykładowe porównanie 24-godzinnej sumy opadów ze stacji synoptycznych z wynikami prognoz modeli ALADIN (wyżej) i AROME (niżej). Przedstawiony wskaźnik POD dla metody Minimum coverage

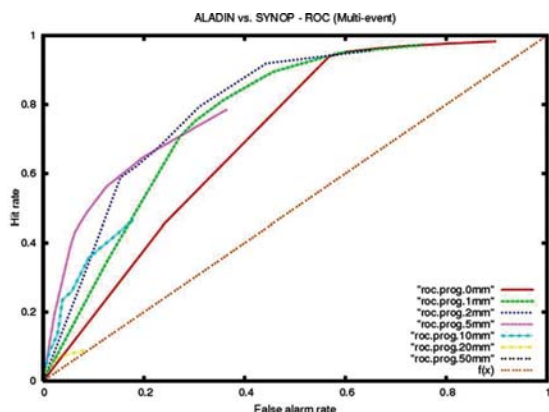


Prognoza opadu całkowitego z modelu ALADIN i AROME oraz dane radarowe (kumulacja 12-godzinnna)



Rozwój metod prognozowania numerycznego o podwyższonej rozdzielczości przestrzennej

Weryfikacja mezoskalowa – metody weryfikacji rozmytej



Przykładowa krzywa ROC dla miesięcznego zestawienia 24-godzinnych sum opadów ze stacji synoptycznych z wynikami modelu ALADIN. Prezentuje wyniki weryfikacji metodą Multi-event

	TS Upscaling					Cum 24				
165km	0,44	0,14	0,39	0,22	0,3	0,06	0			
85km	0,42	0,19	0,29	0,15	0,26	0,34	0			
45km	0,36	0,03	0,18	0,07	0,14	0,21	0			
25km	0,38	0,06	0,15	0,08	0,18	0,25	0			
15km	0,4	0,05	0,15	0,11	0,17	0,27	0			
10km	0,39	0,03	0,12	0,07	0,17	0,28	0			
5km	0,19	0,01	0,06	0,02	0,04	0,12	0			
1km	0	0	0	0	0	0	0			
	0	1	2	5	10	20	50			

	TS Upscaling					Cum 24				
165km	0,74	0,08	0,33	0,23	0,44	0,07	0			
85km	0,64	0,26	0,25	0,18	0,37	0,36	0			
45km	0,52	0,04	0,19	0,12	0,23	0,28	0			
25km	0,47	0,05	0,13	0,09	0,2	0,26	0			
15km	0,47	0,1	0,08	0,08	0,19	0,3	0			
10km	0,47	0,13	0,03	0,06	0,17	0,24	0			
5km	0,44	0,04	0,06	0,06	0,15	0,25	0			
1km	0,17	0	0,01	0	0,05	0,09	0			
	0	1	2	5	10	20	50			

Przykładowe porównanie 24-godzinnej sumy opadów ze stacji synoptycznych z wynikami prognoz modelu ALADIN (wyżej) i AROME (niżej). Przedstawiony wskaźnik TS dla metody Upscaling

Zastosowania kompozytowych filtrów medianowych

Filtry medianowe, szeroko stosowane w dziedzinie przetwarzania obrazów celem redukcji szumów, są solidną podstawą do stworzenia narzędzia do separacji skal przestrzennych dla pól niegładkich, takich jak pole opadu czy zachmurzenia. Proponowanym do tego celu rozwiązaniem jest zbiór iteracyjnych, 4-kierunkowych, ważonych, kompozytowych filtrów medianowych (ang. Iterative Four-Directional Composite Weighted Median Filters, w skrócie Filtry ICWM).

Dwuwymiarowe filtry ICWM są superpozycją jednowymiarowych filtrów medianowych o różnych rozmiarach i wagach zastosowanych do iteracyjnego wygładzania w kilku różnych kierunkach. Takie filtry wykazują interesujące własności, wśród nich odporność statystyczną i idempotentność – ta ostatnia własność została udowodniona tylko na poziomie eksperymentów numerycznych.

Porównanie pól 12-godzinnych sum opadów z następujących źródeł: ALADIN (konfiguracja operacyjna – rozdzielczość 13,5km), AROME (konfiguracja eksperymentalna – rozdzielczość 2,7km) i dane radarowe z sieci POLRAD. Oryginalne pola zostały przekonwertowane do wspólnej, regularnej siatki. Zaprezentowane wyniki kolejnych filtracji pól opadów z pomocą dwuwymiarowych filtrów ICWM z dwuparametrową kwantyzacją. Przykłady te odkrywają potencjał filtrów ICWM jako narzędzia separacji skal oraz podstawy nowych metod analizy i weryfikacji

