

Prognozowanie zapotrzebowania na energię/produkcji energii dla fragmentu sieci OSD

dr hab. inż. Dariusz Baczyński
dr inż. Marcin Kopyt

**Politechnika
Warszawska**

22 kwietnia 2026 roku



Motywacja

1

- Znaczna liczba OZE, w tym prosumenckich
- Potencjalne koszty zakupu proporcjonalne do liczby punktów
- Większe koszty przetwarzania i magazynowania dużych ilości danych
- Potencjalne cyberataki na serwery obliczeniowe i awarie systemów prognoz
- Zawodność lokalnych prognoz pogody

Fizyczne podstawy projektowanego rozwiązania

Obszar-stacja SN lub WN/SN wraz z podłączeniami
 Superobszar-wszystkie obszary razem

Obszar i superobszar może posiadać:

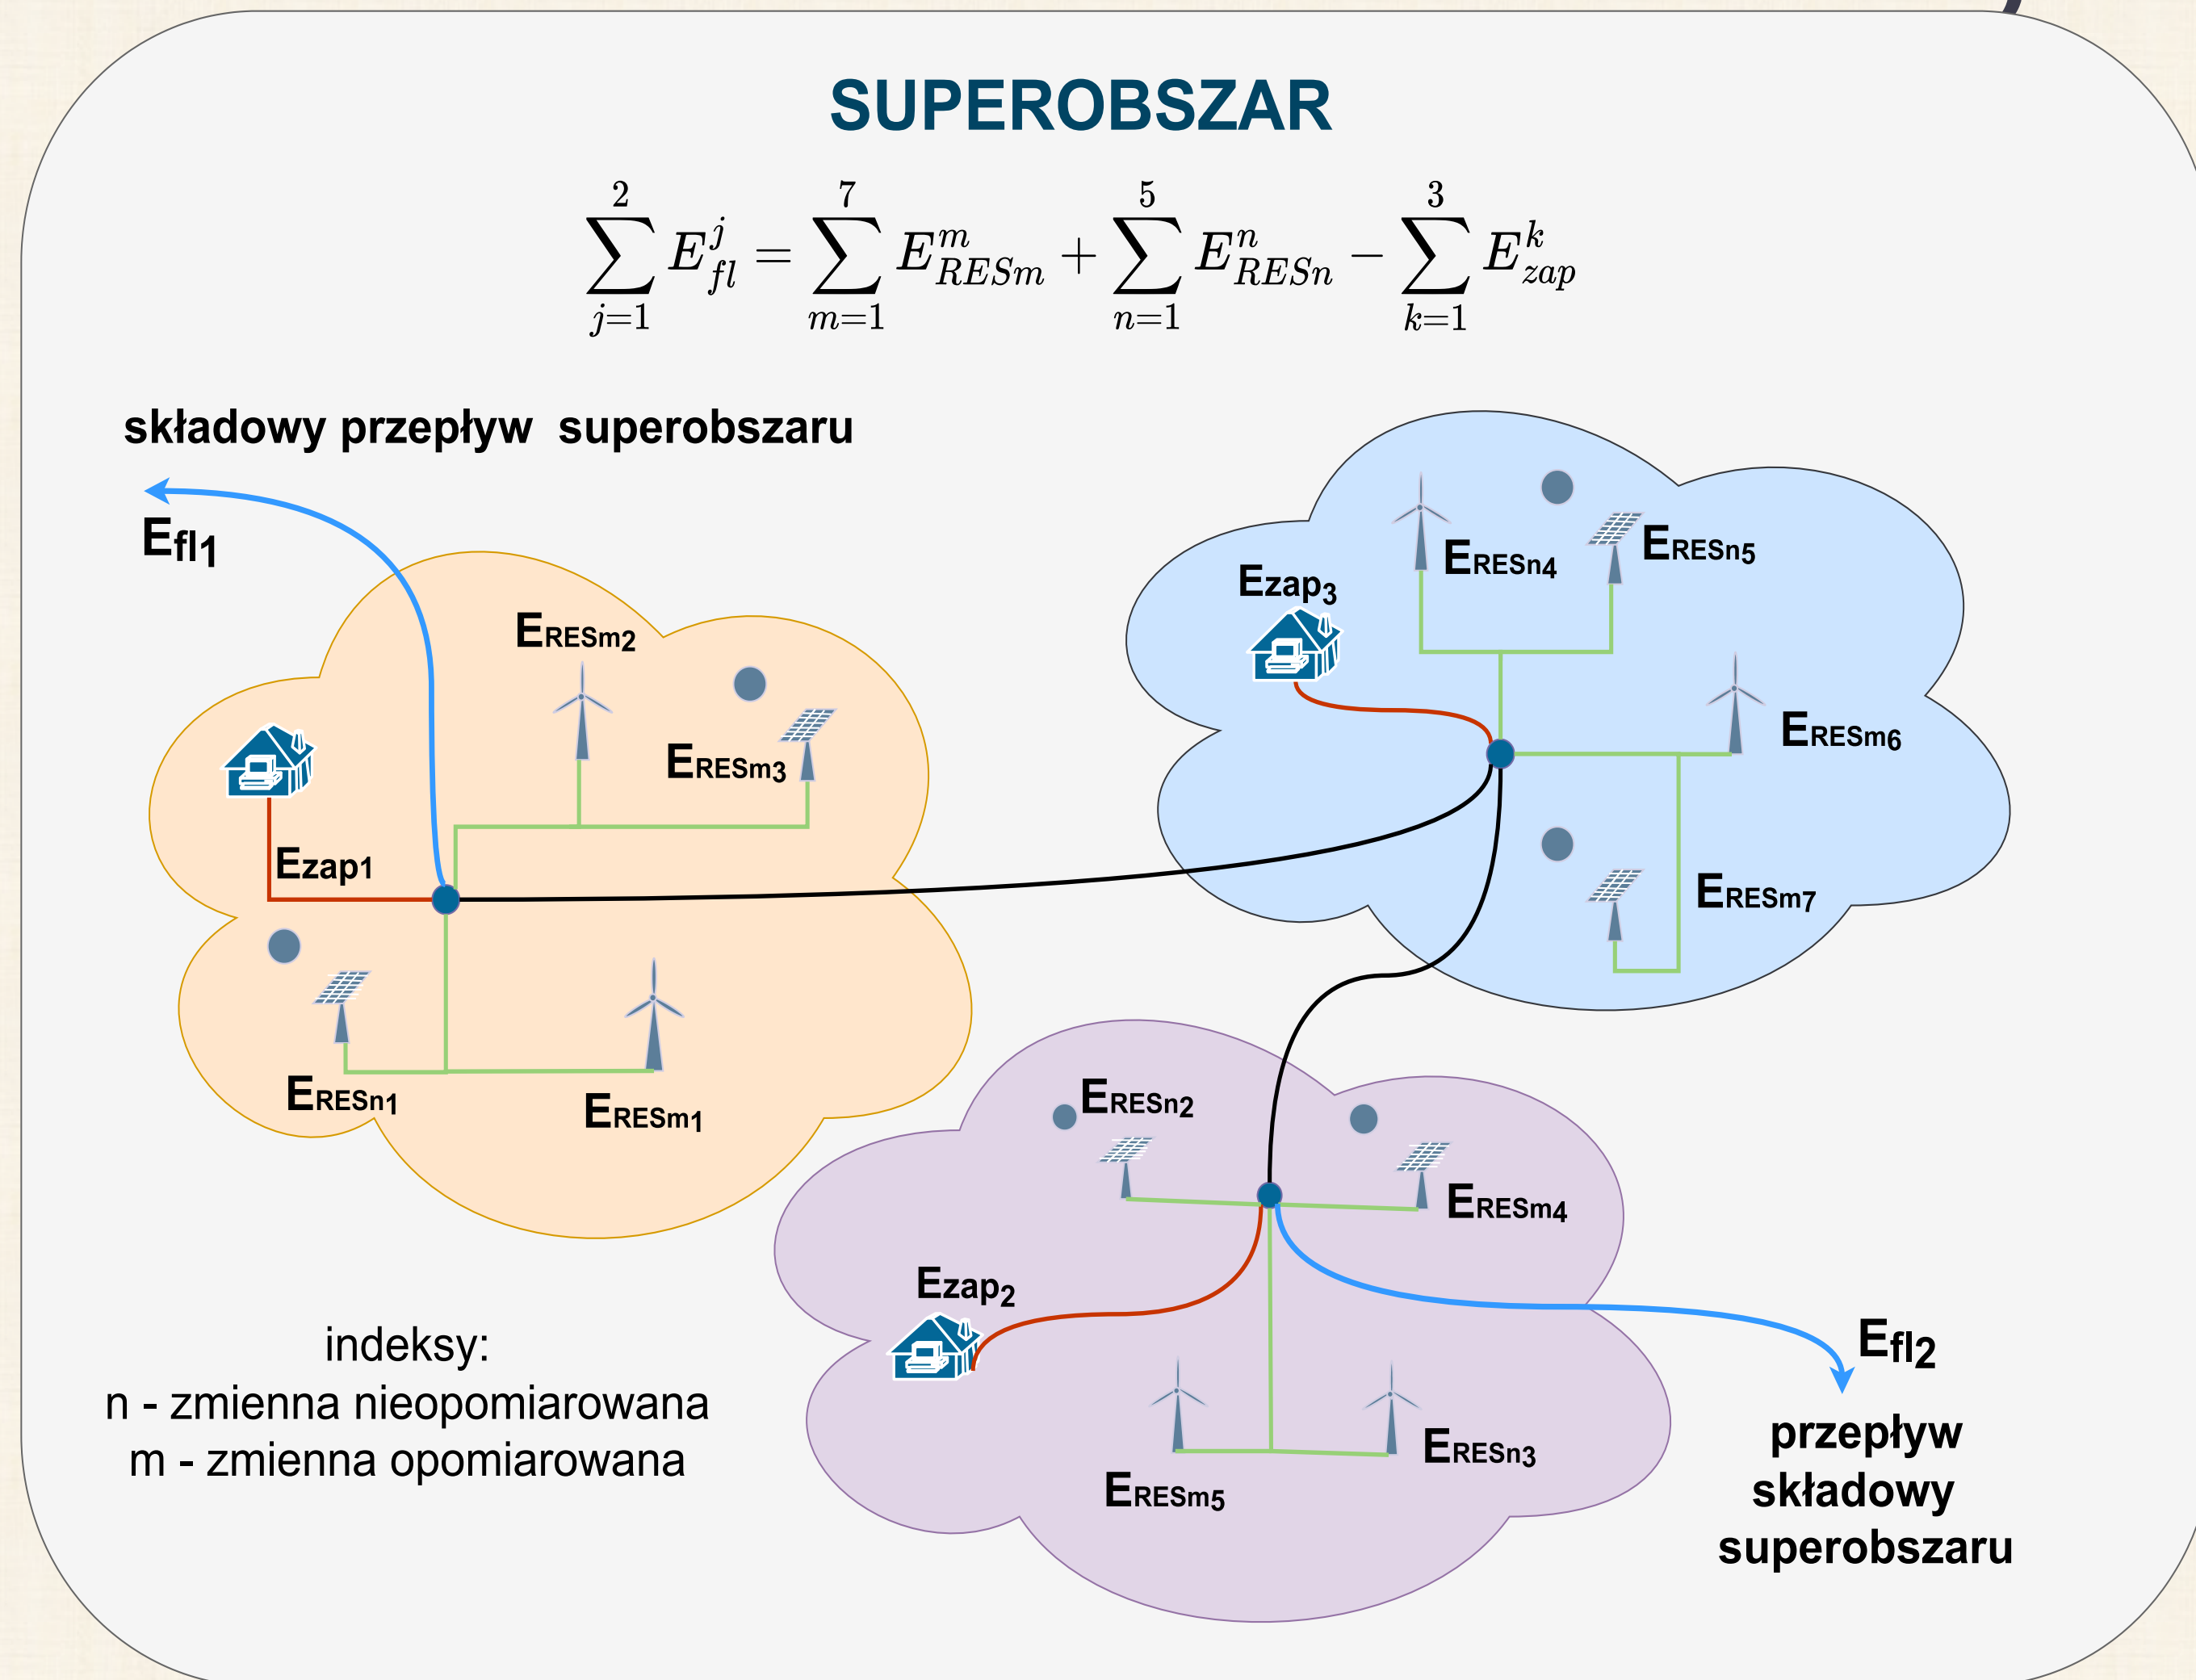
- Opomiarowaną generację E_{RESm}
- Opomiarowane przepływy energii E_{fl}
- Nieopomiarowaną generację E_{RESn}
- Zapotrzebowanie E_{zap}
- Wymianę energii z siecią zewnętrzną

Zmienne te wiążę ze sobą równanie:

- $E_{fl} = E_{RESm} + E_{RESn} - E_{zap}$

Dla superobszaru E_{fl} wymianę energii z siecią zewnętrzną 110 kV.

Dla stacji SN oznacza to zaś wypadkowe saldo energii przechodzącej przez transformatory stacji



Schemat sytuacyjny na przykładzie superobszaru o trzech obszarach składowych

- *prognozy sald energii w wariancie wykorzystującym punktowe i obszarowe prognozy pogody,*
- *budowa systemu korekt prognoz obszarowych energii elektrycznej*
- *analiza możliwości odtwarzania prognoz energii elektrycznej dla obiektów niżej w hierarchii lokalnego obszaru bilansowania na podstawie prognoz dla obiektów znajdujących się wyżej w hierarchii*

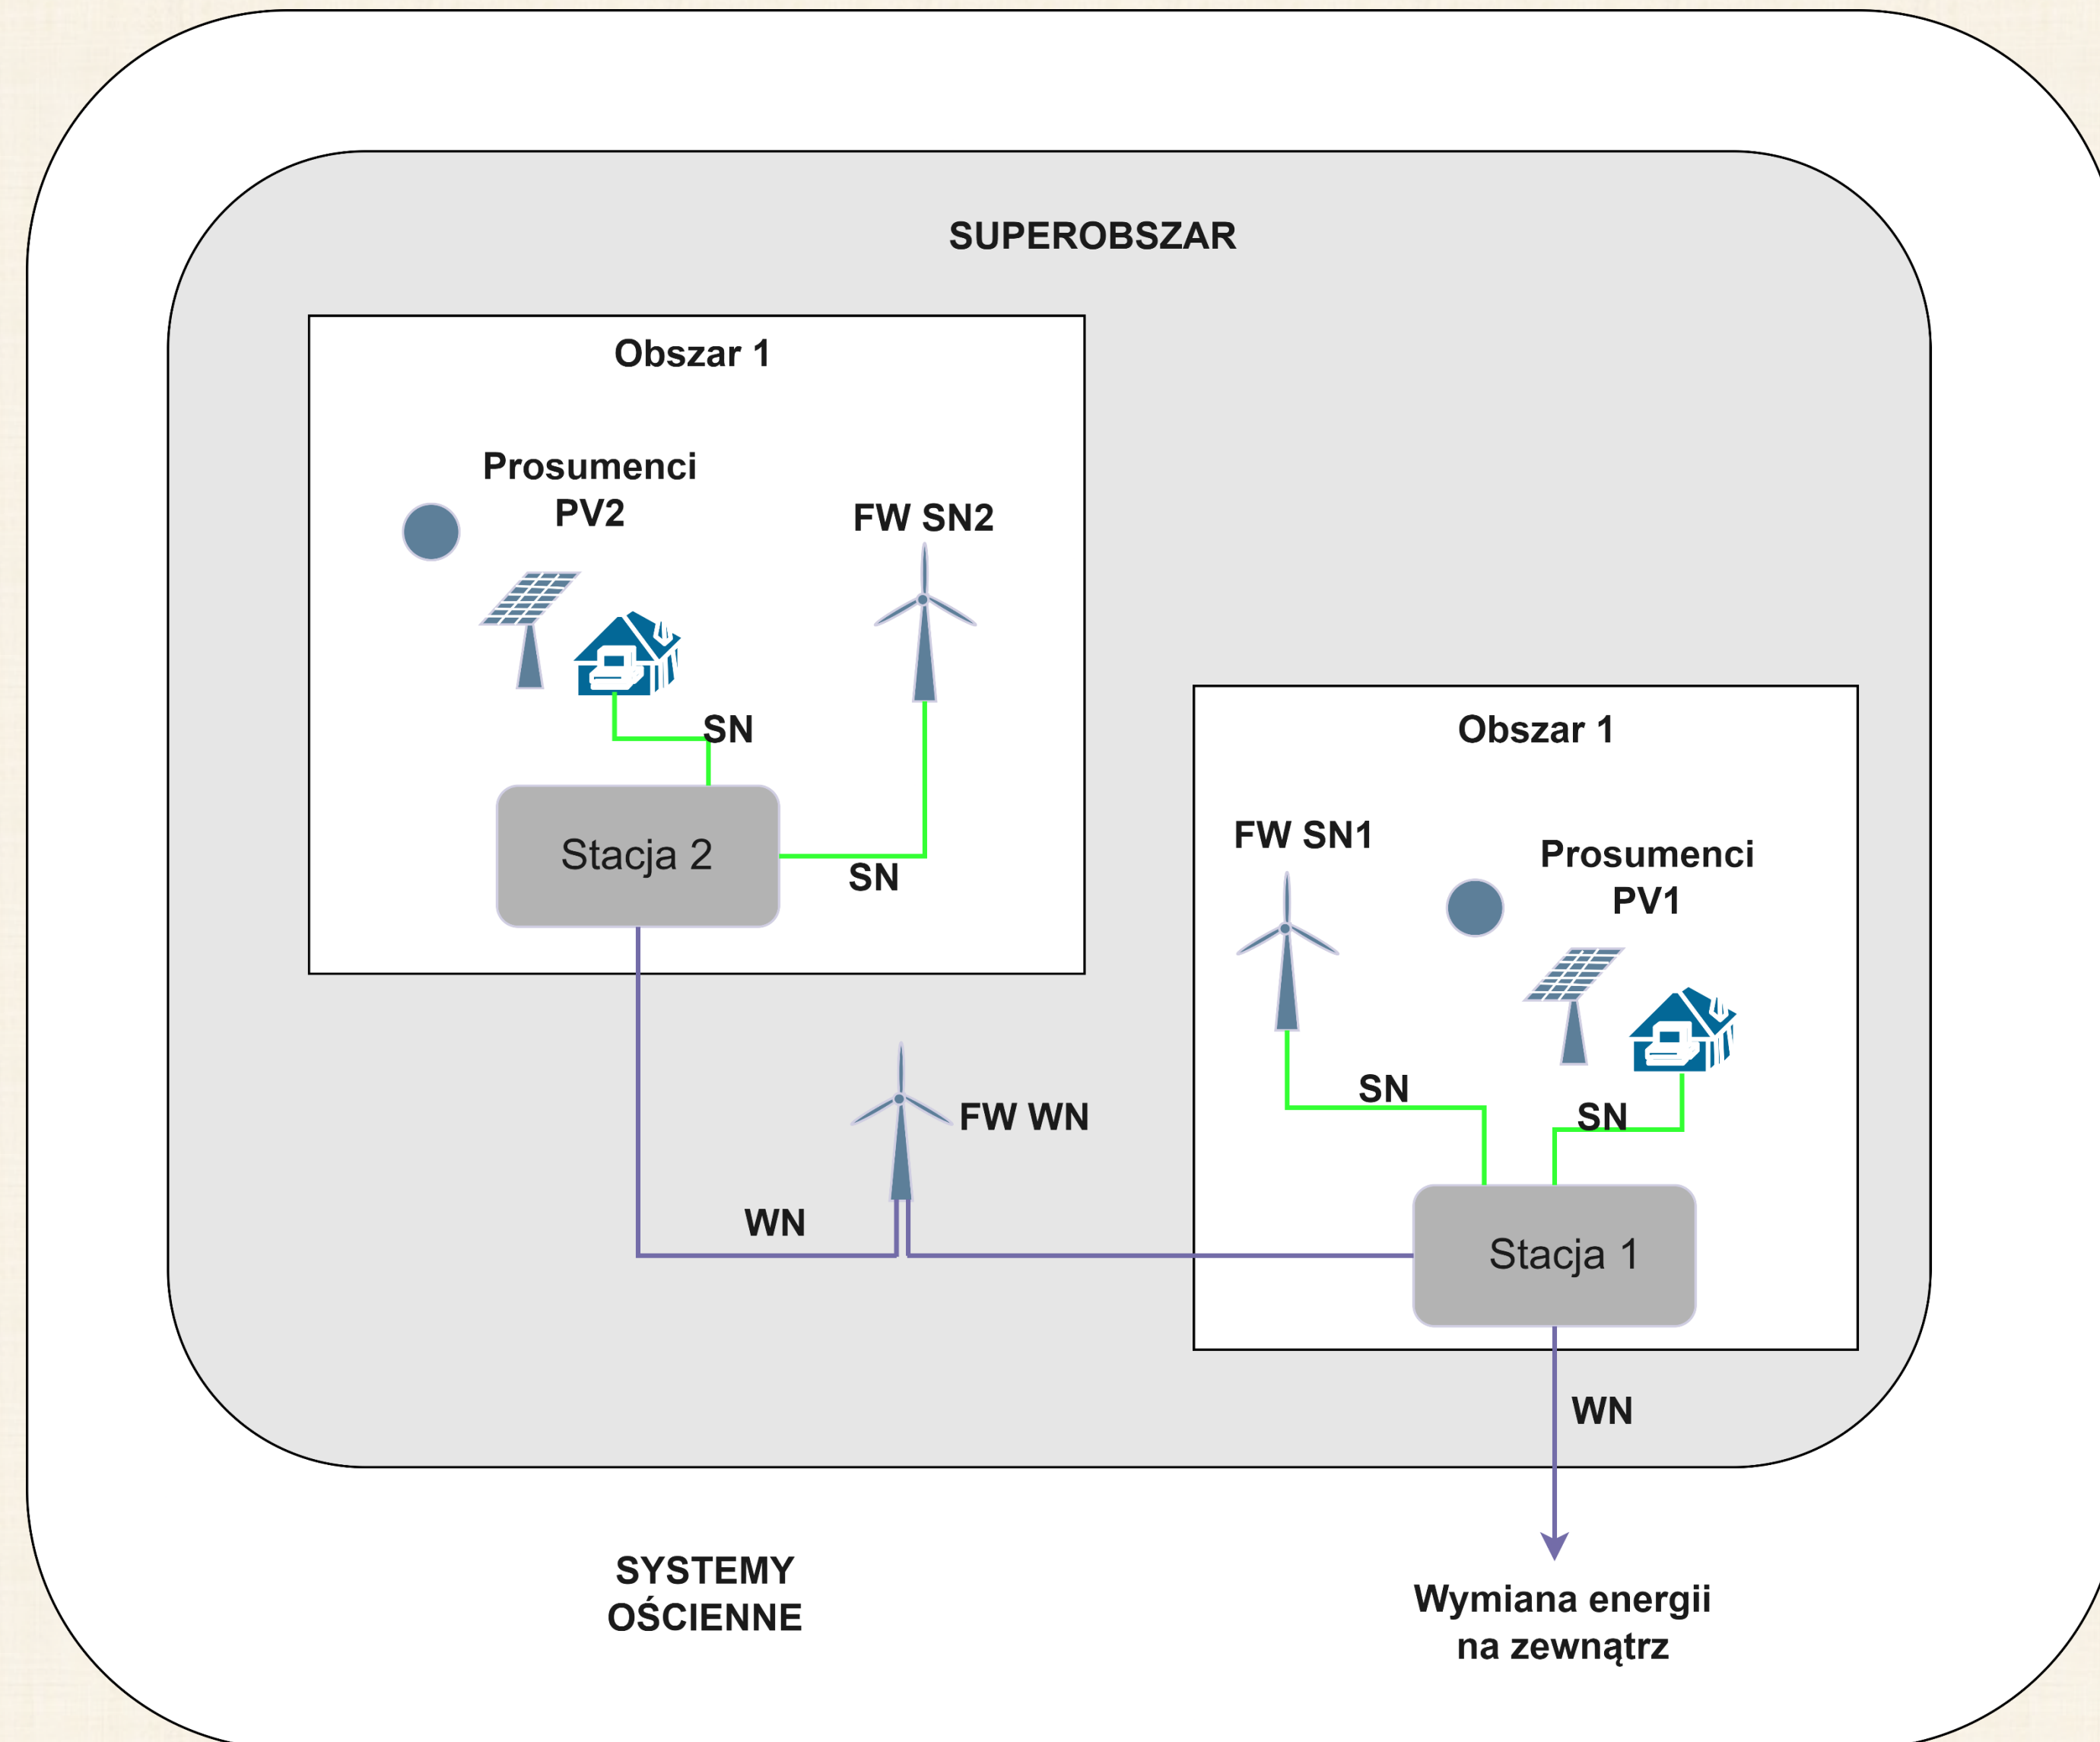
- 1. Dostosowanie danych do notacji projektowej i sprawdzenie bilansowania się danych celem określenia poprawności danych*
- 2. Prognoza E_{fl} i $ERES_m$ dla superobszaru.*
- 3. Prognoza E_{fl} i $ERES_m$ dla poszczególnych obszarów.*
- 4. Porównanie prognoz obszarowych z wynikami prognoz punktowych*
- 5. Uzgodnienie prognoz pomiędzy superobszarem i poszczególnymi obszarami.*
- 6. Opracowanie modeli rozdziału przepływu energii i generacji opomiarowanej w superobszarze na poszczególne obszary*

Charakterystyka danych energetycznych do prognoz

5

Pierwszy komplet danych

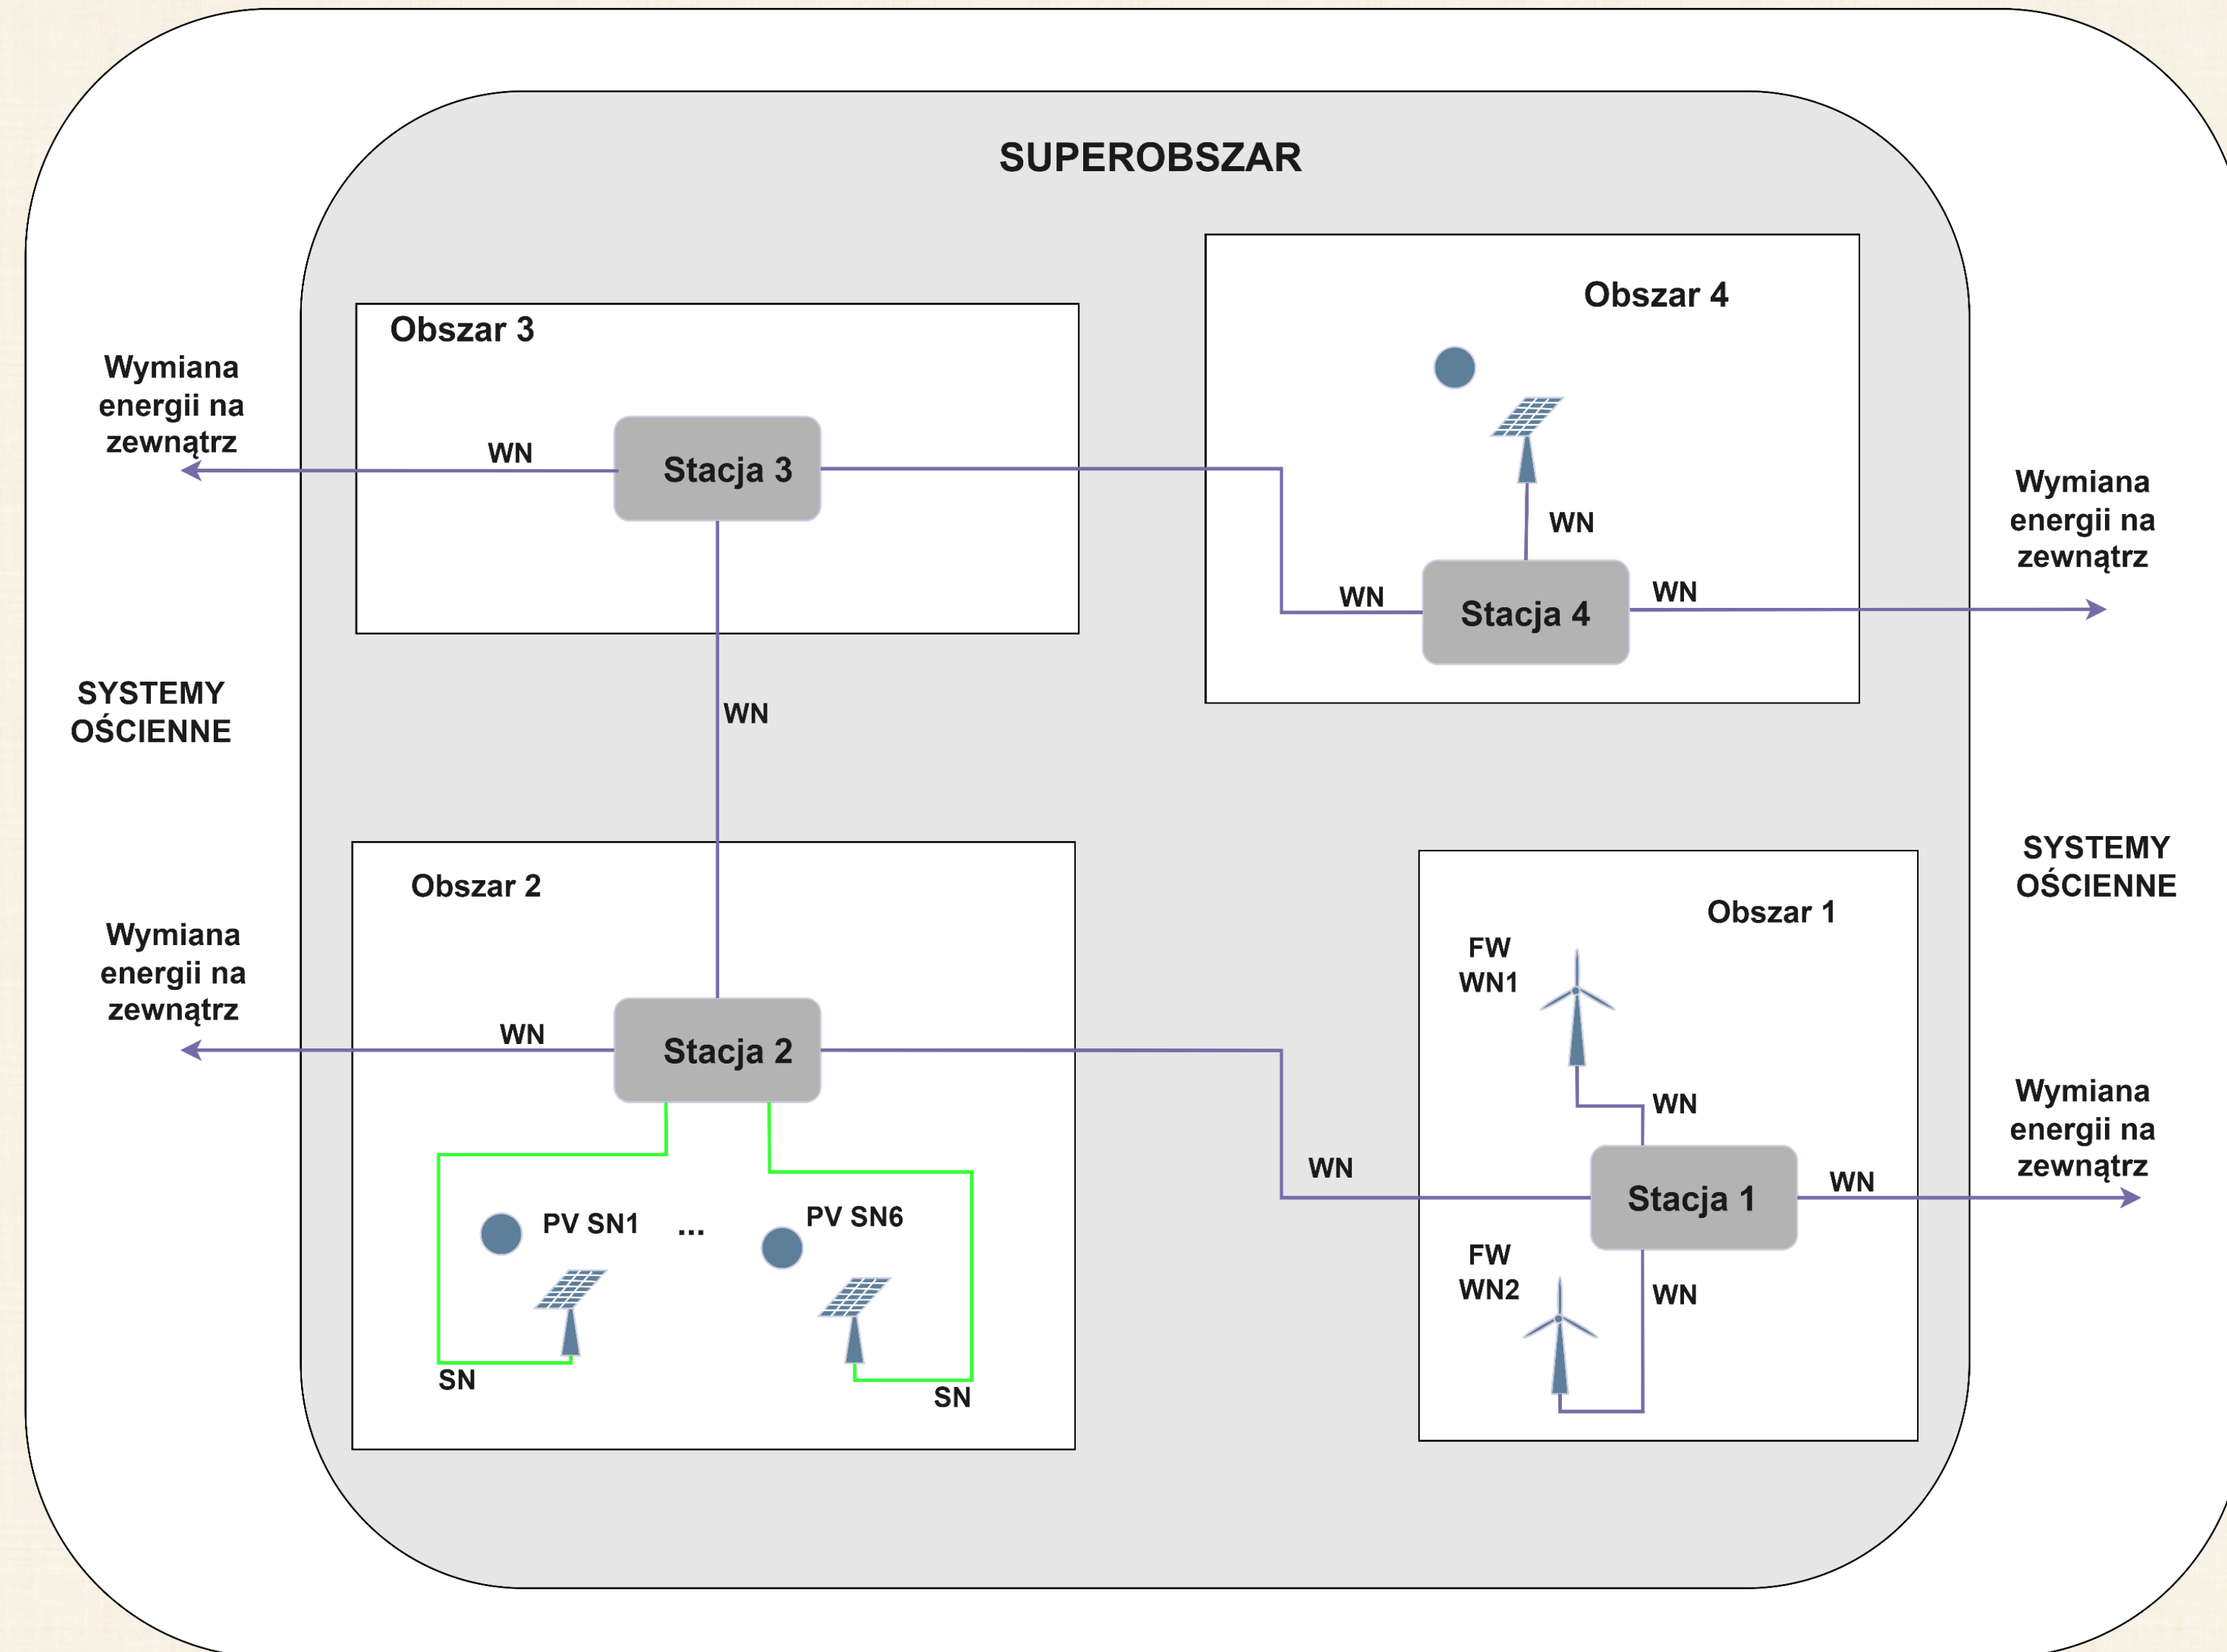
- 2 stacje WN/SN
- 1 FW WN
- 2 FW SN
- 2 zagregowanych prosumentów PV



Charakterystyka danych energetycznych do prognoz

Drugi komplet danych

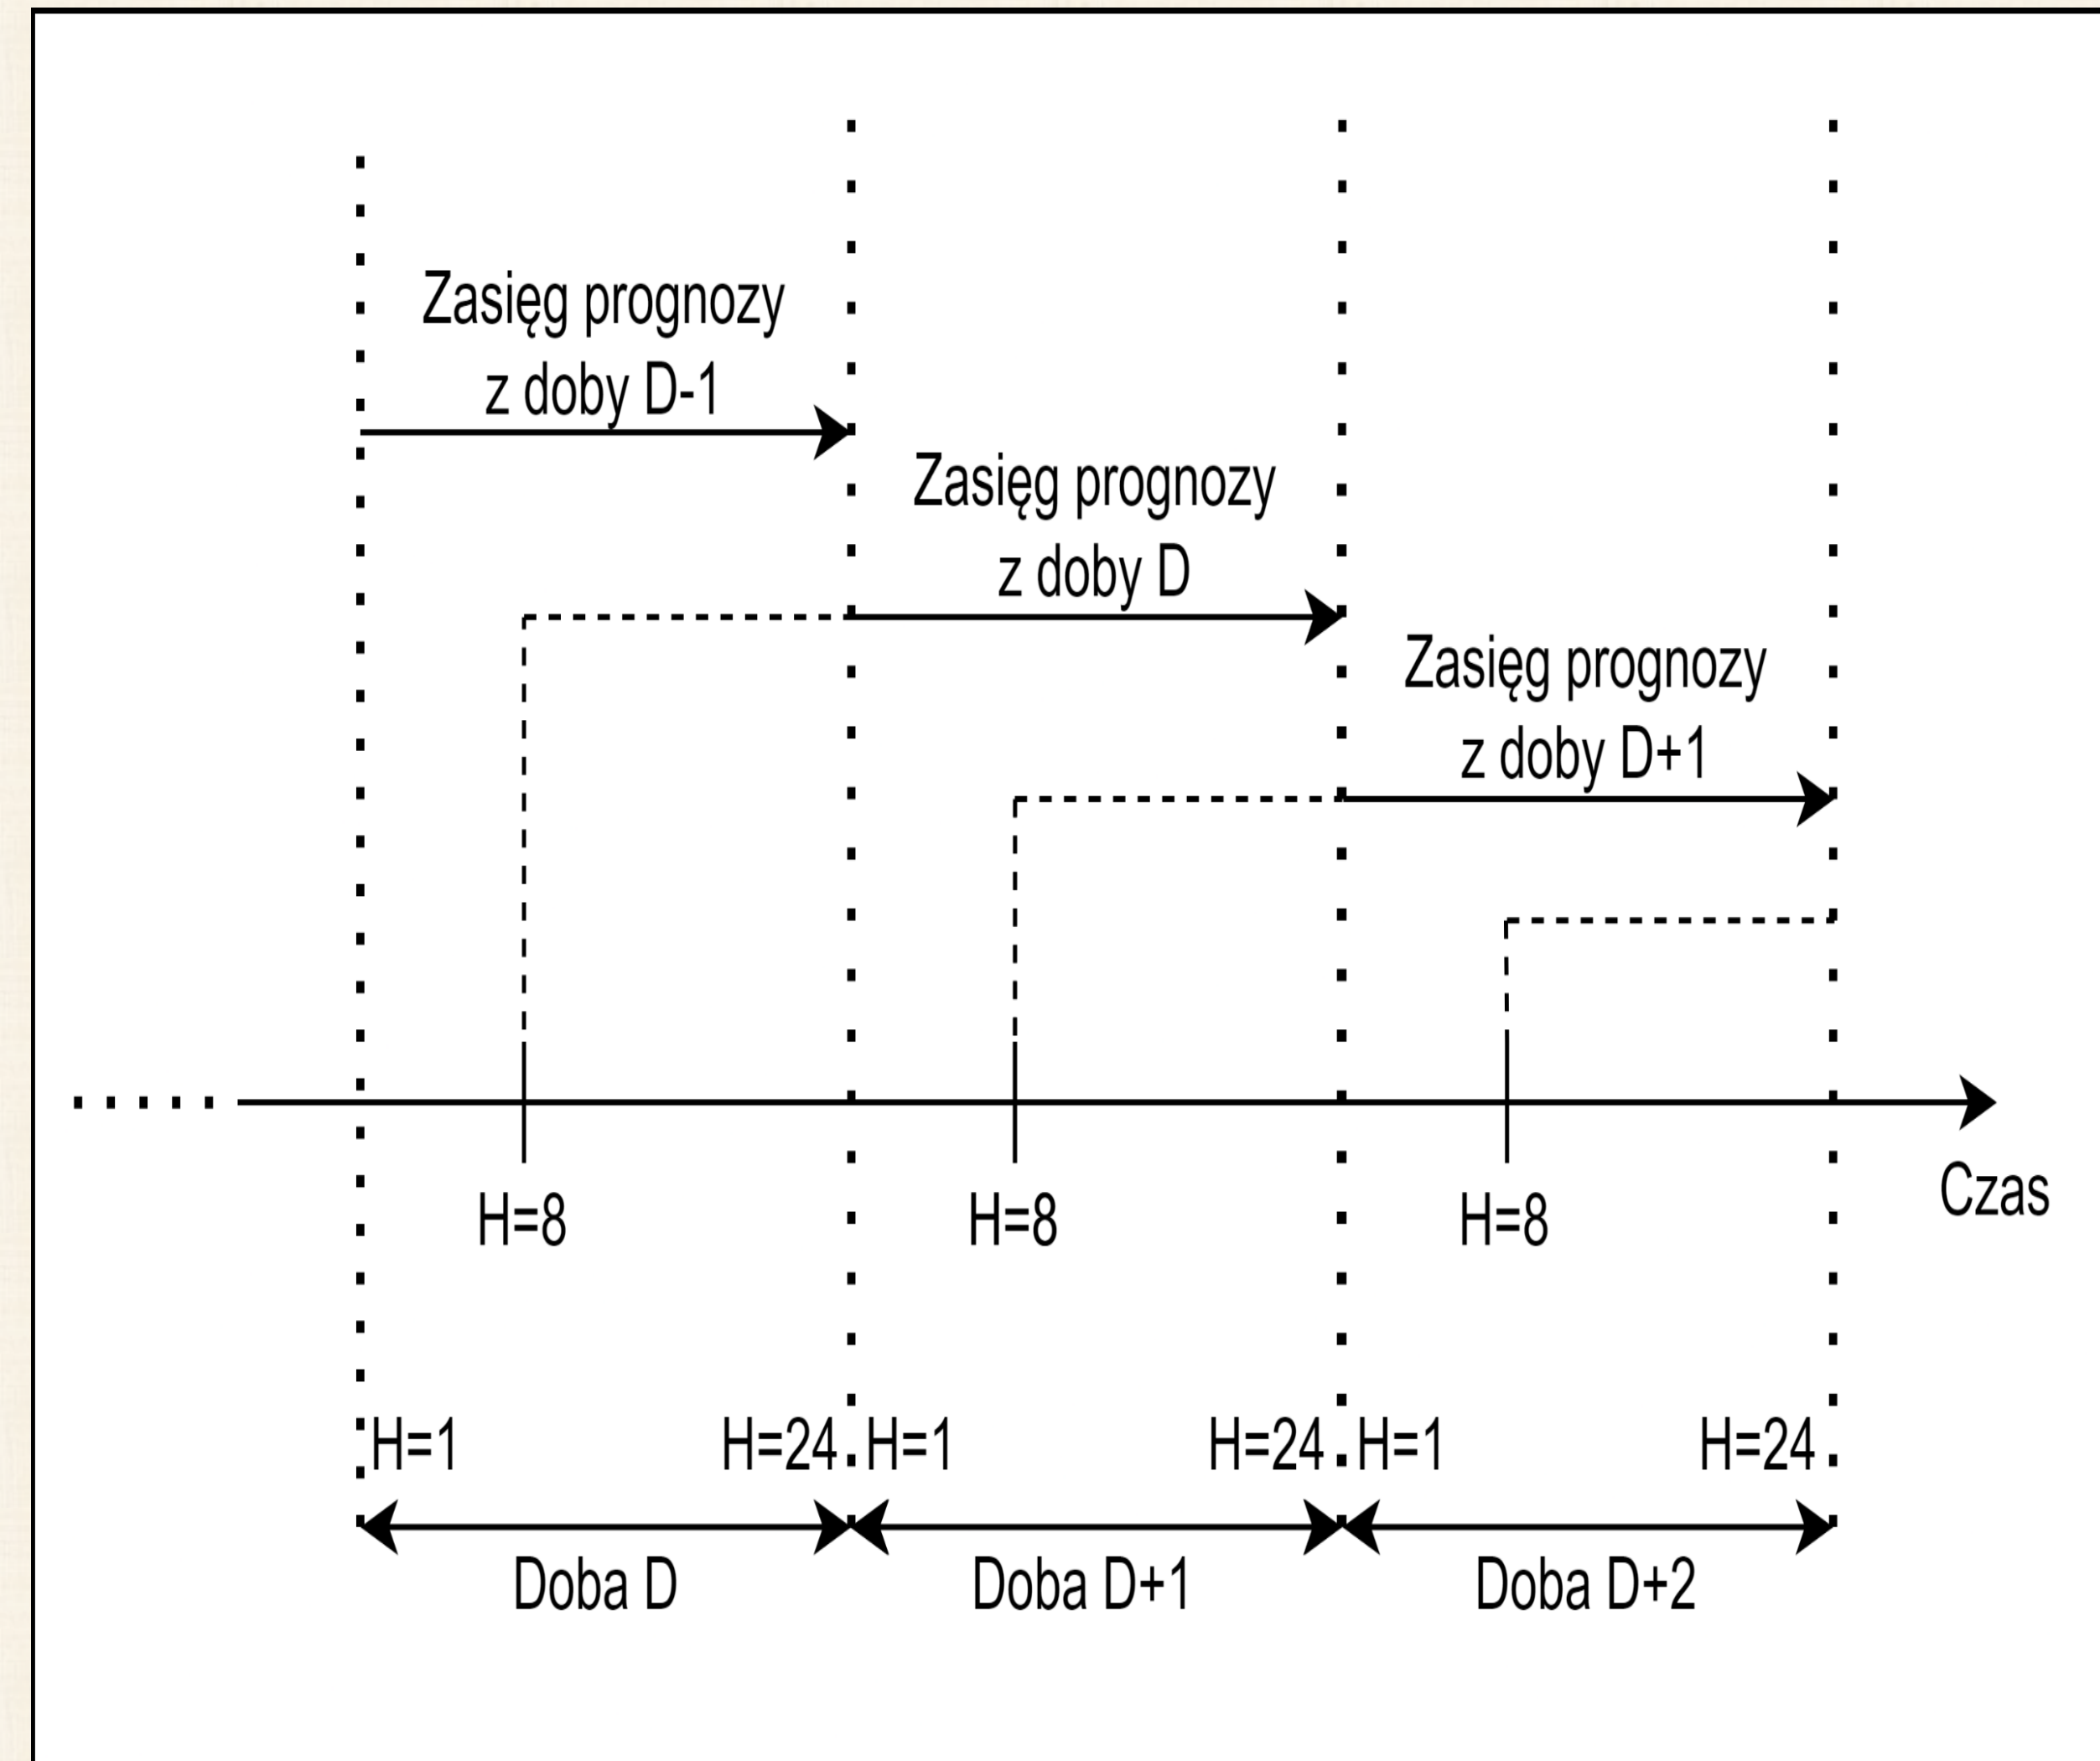
- 4 stacje WN/SN
- 2 FW WN
- 1 PV WN
- 1 PV SN



Charakterystyka prognoz przepływów energii do wykonania

7

- Kwantyzacja 1h
- Każdy model prognozuje przepływy energii na dobę $d+1$
- Prognoza codziennie o godzinie 8
- NMAE [%],
- Dane wejściowe punktowe – albo obszarowe
- Metody: Naiwna($t-48$), XGBoost, LSTM



Charakterystyka danych wejściowych do prognoz przepływów energii

Prognozowane zmienne – po lewej pierwszy komplet danych(8 obiektów), po prawej drugi (10 ob.)

Nazwa zmiennej	Opis
E_{fl_GPZ1}	Saldo przepływu energii dla pierwszej stacji WN/SN
E_{fl_GPZ2}	Saldo przepływu energii dla drugiej stacji WN/SN
$E_{fl_superobszaru}$	Saldo przepływu energii dla superobszaru
E_{RESm_GPZ1}	łączna generacja opomiarowana spływająca do GPZ1 z poziomu SN
E_{RESm_GPZ2}	łączna generacja opomiarowana spływająca do GPZ2 z poziomu SN
E_{RESm_WN}	łączna generacja opomiarowana superobszaru (na poziomie WN)
$E_{fl_prosumenci_GPZ1}$	Saldo przepływu energii dla prosumentów PV związanych ze stacją GPZ1
$E_{fl_prosumenci_GPZ2}$	Saldo przepływu energii dla prosumentów PV związanych ze stacją GPZ2

Nazwa zmiennej	Opis
E_{fl_GPZ1}	Saldo przepływu energii dla pierwszej stacji WN/SN
E_{fl_GPZ2}	Saldo przepływu energii dla drugiej stacji WN/SN
E_{fl_GPZ3}	Saldo przepływu energii dla trzeciej stacji WN/SN
E_{fl_GPZ4}	Saldo przepływu energii dla czwartej stacji WN/SN
$E_{fl_superobszaru}$	Saldo przepływu energii dla superobszaru
$E_{RESm_GPZ1_FW1}$	Generacja opomiarowana spływająca do GPZ1 z farmy wiatrowej 1 (z WN)
$E_{RESm_GPZ1_FW2}$	Generacja opomiarowana spływająca do GPZ1 z farmy wiatrowej 2 (z WN)
E_{RESm_GPZ2}	łączna generacja opomiarowana spływająca do GPZ2 (z SN)
E_{RESm_GPZ4}	łączna generacja opomiarowana spływająca do GPZ4 (z WN)
E_{RESm_WN}	łączna generacja opomiarowana superobszaru (z WN)

Dobór danych wejściowych do prognoz przepływów energii – podejście kaskadowe

9

- *Pierwszy stopień kaskady kończył się wyborem modelu ML o najniższym błędzie na zbiorze walidacyjnym, po czym następowało przejście do drugiego stopnia kaskady.*
- *Pierwszy stopień kaskady uwzględniał dane pogodowe – wiatry nasłonecznienia, temperaturę, opady*
- *Drugi stopień uwzględniał w kombinacjach :*
 - *opóźnione czasowo wyjścia*
 - *dane czasowe,*
 - *marker dnia/nocy,*
 - *marker typu dnia*
 - *kombinacje tych zmiennych razem lub z modelem najlepszym z pierwszego stopnia*

Podział na dane *tre-val-test*

10

Zakres danych	Oznaczenie kodowe	Ramy czasowe zakresu dla pierwszego zbioru danych	Ramy czasowe zakresu dla drugiego zbioru danych
Uczący	Train + val	09-04-2016 - 31-12-2017	04-01-2021 - 31-12-2021
Test	test	01-01-2018 do 31-12-2018	01-01-2022 do 18-05-2022

Hiperparametry modeli predykcyjnych

11

Model XGBoost (w sumie 108 kombinacji parametrów)

Dla każdej kombinacji danych wejściowych rozważano różne wartości parametrów

N_estimators, Max_depth , Learning_rate , MIN_CHILD_WEIGHT, gamma

Model LSTM (w sumie 48 kombinacji parametrów)

Dla każdej kombinacji danych wejściowych rozważano w modelu różne wartości

parametrów:

- Liczbę neuronów w 1 i 2 warstwie ukrytej
- Funkcję aktywacji warstwy ukrytej
- Maksymalną liczbę iteracji
- „Cierpliwość” metody

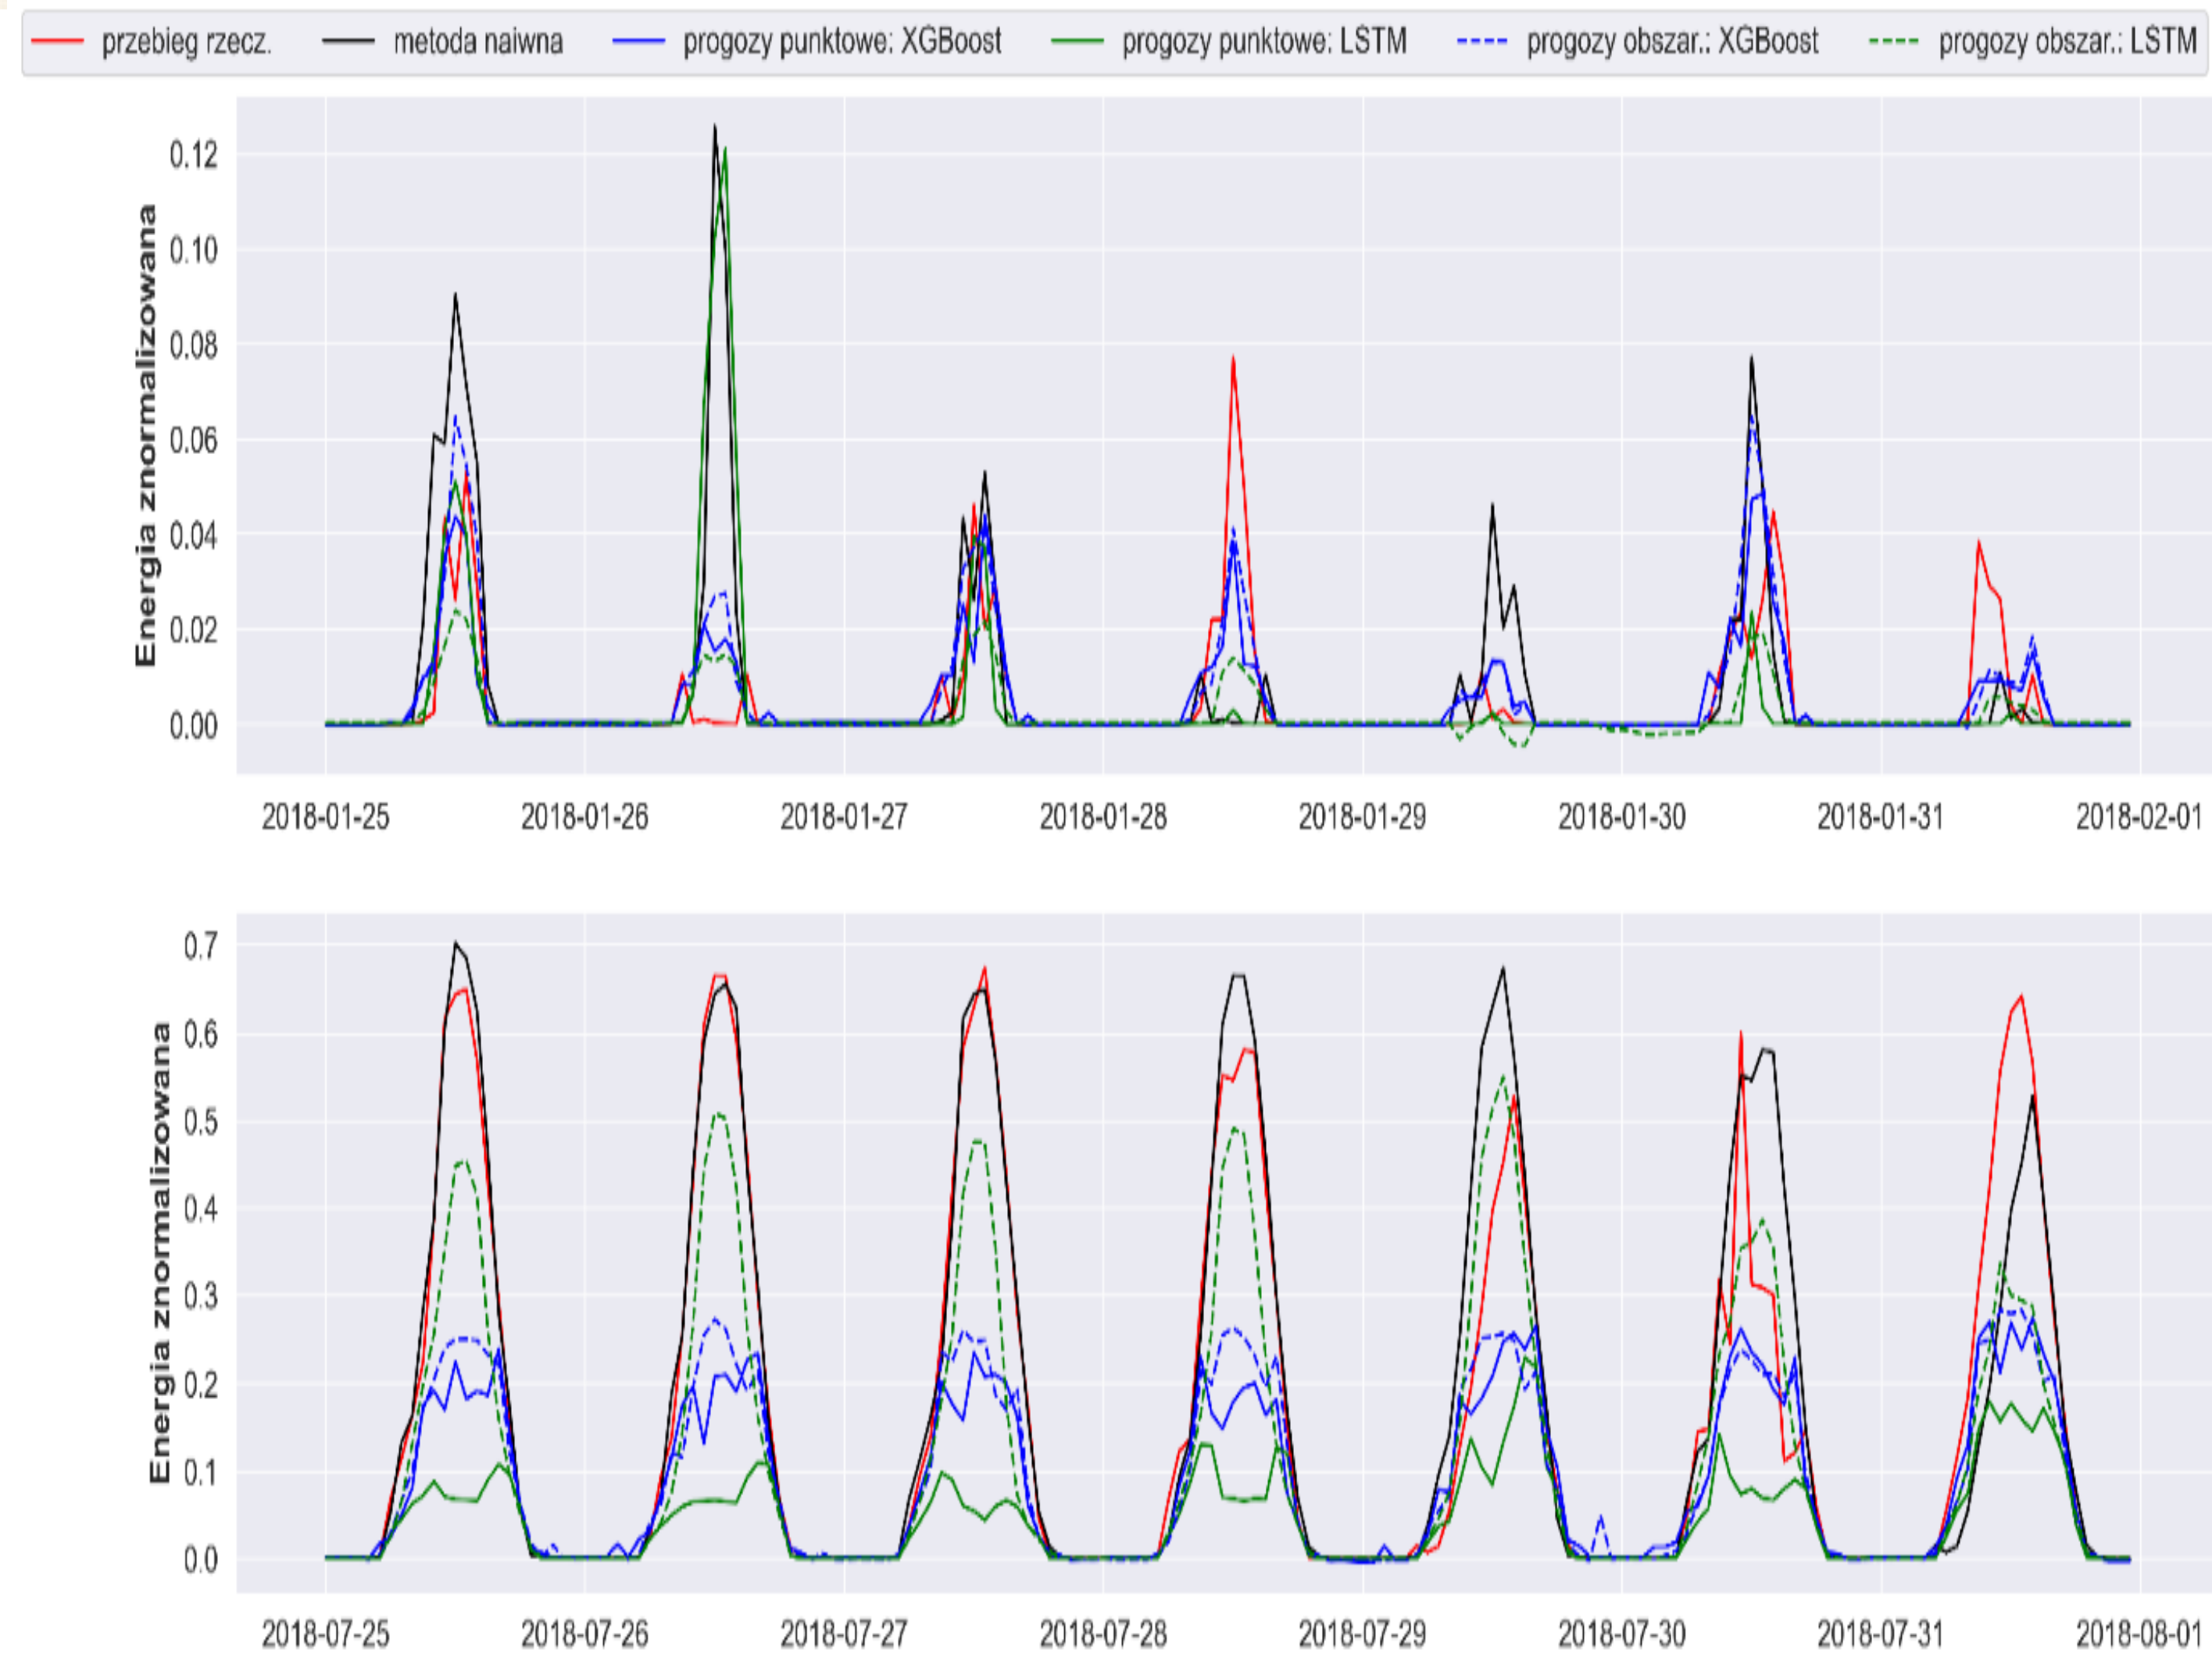
W sumie zbudowano ponad 5508 modeli XGBoost i 2448 modeli LSTM

(razy 2 – podejście obszarowe i punktowe)

Wyniki prognoz – pierwszy zbiór danych cz1

12

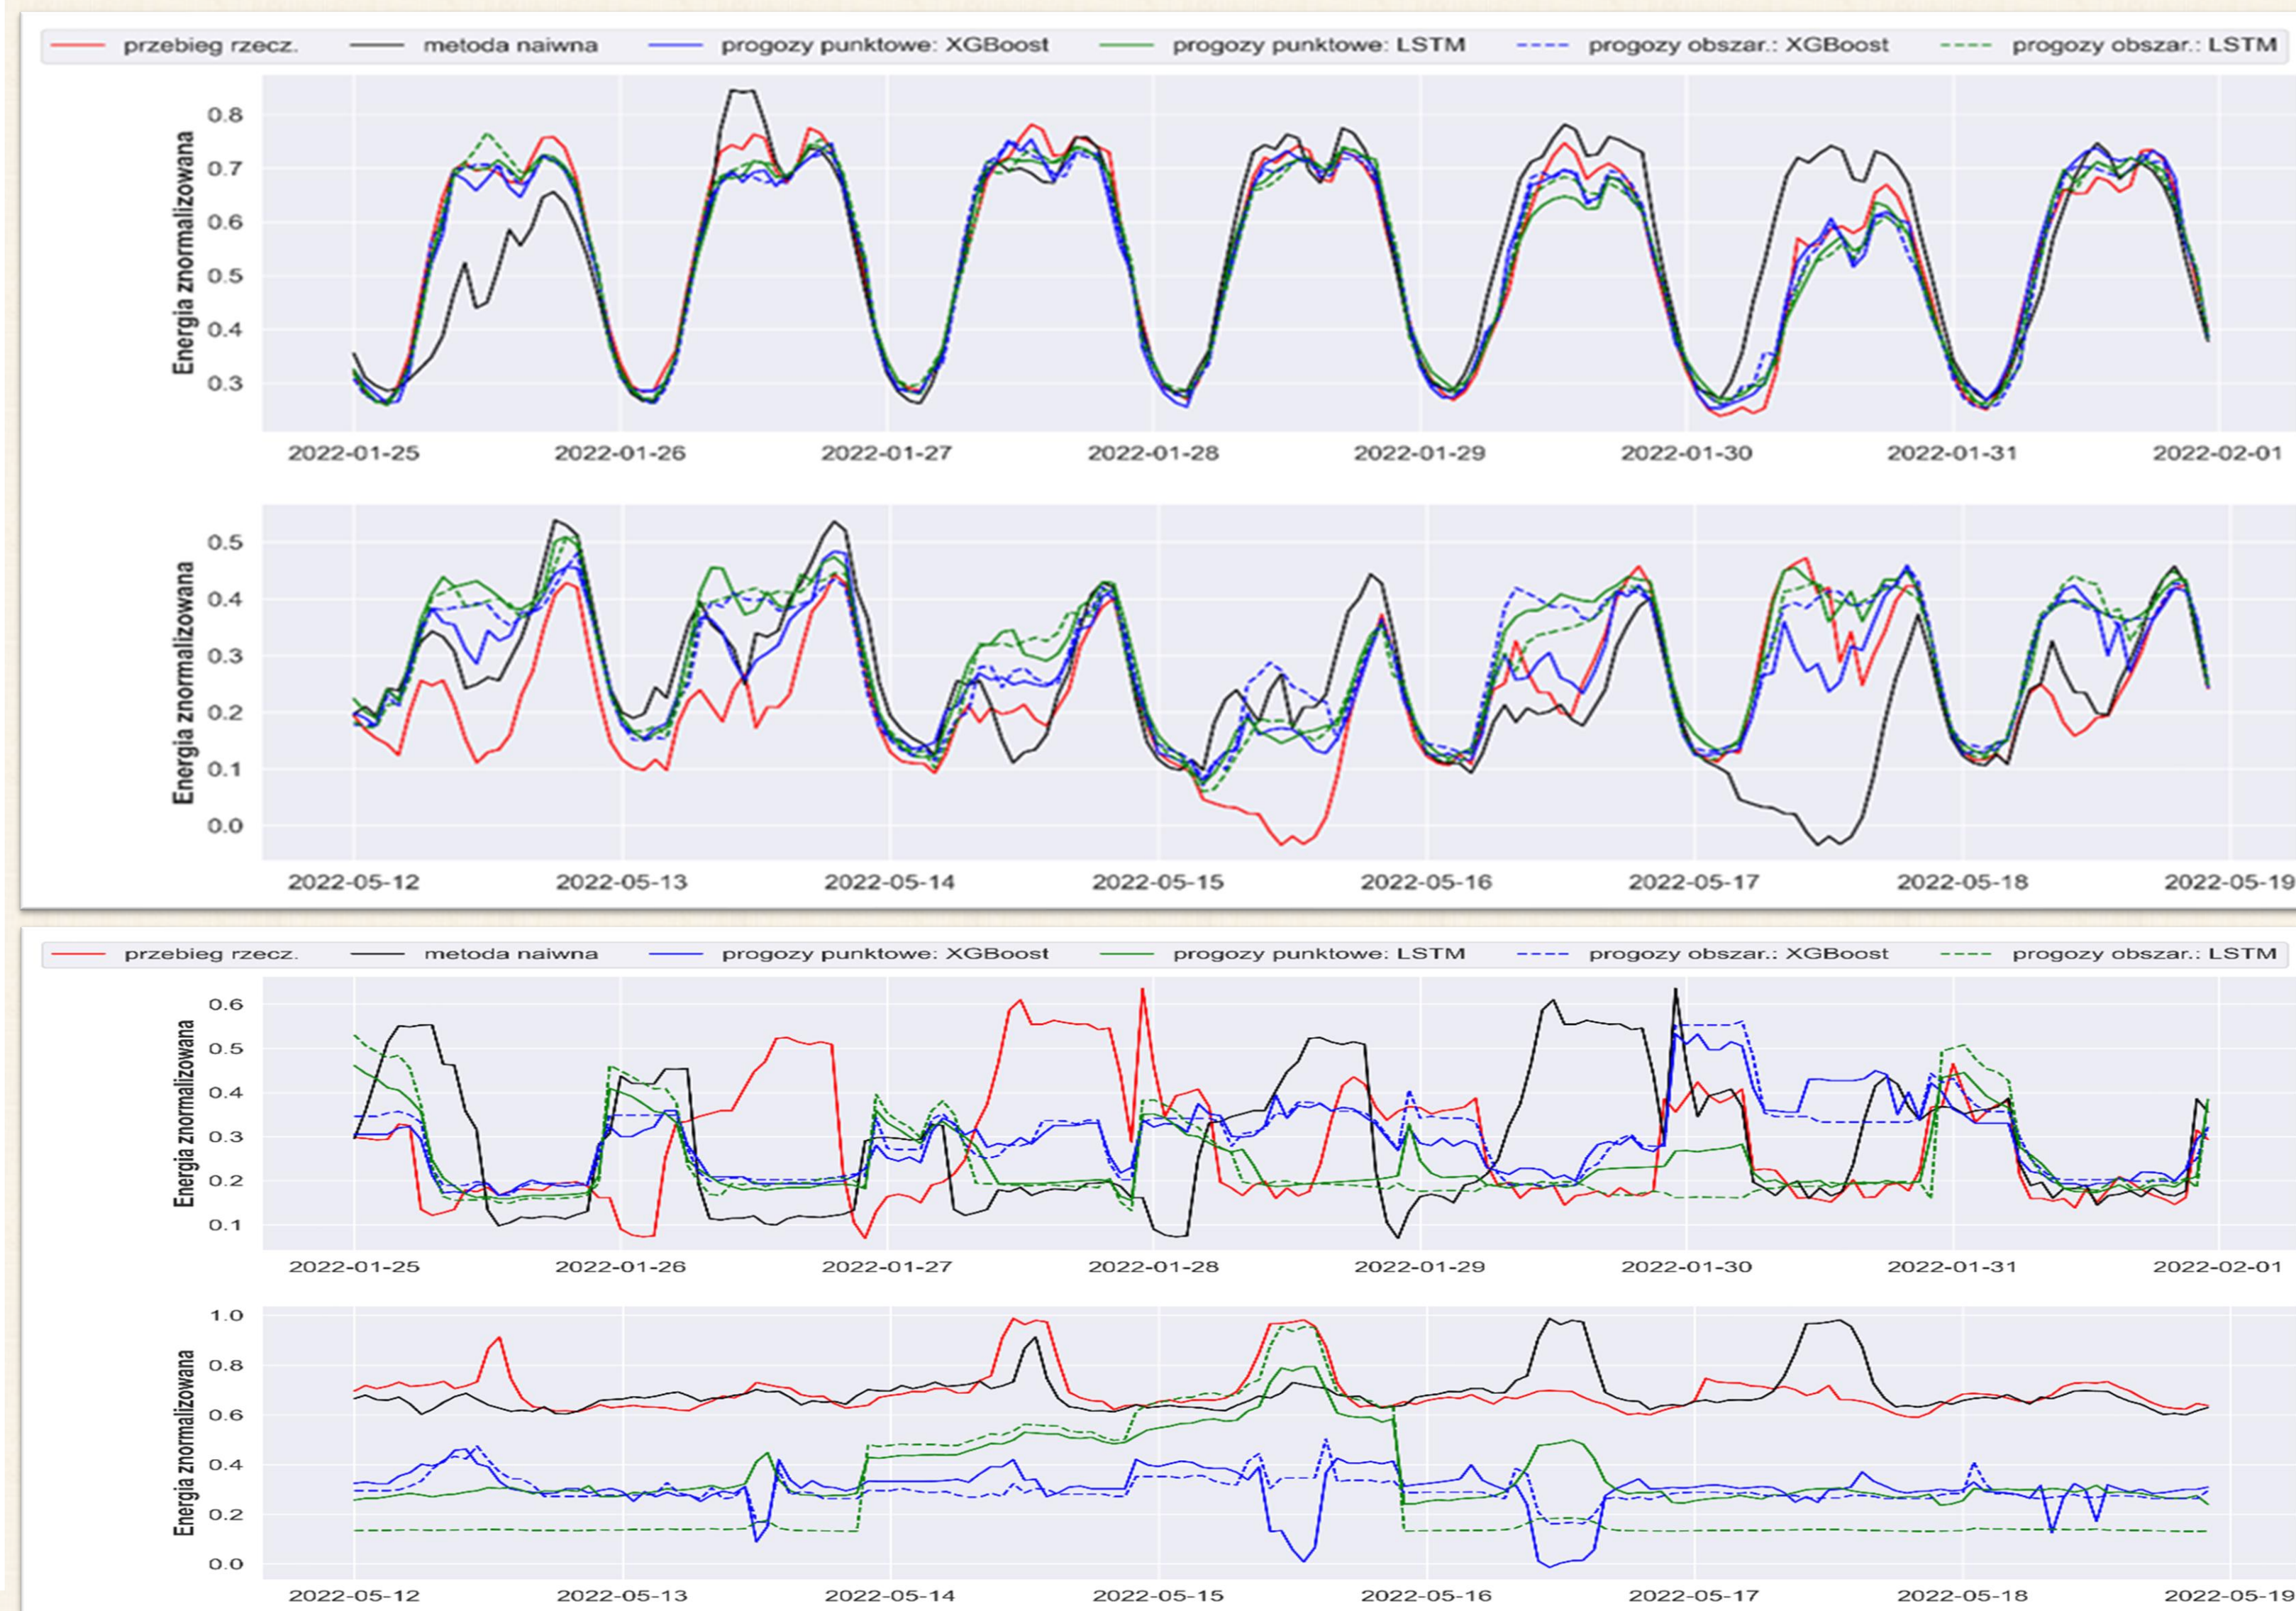
zmienna	Typ	Metoda naiwna	prognozy punktowe		prognozy obszarowe	
		NMAE [%]	NMAE [%] XGboost	NMAE [%] LSTM	NMAE [%] XGboost	NMAE [%] LSTM
E _{fi} _prosumenci_GPZ1	train	1.79	1.01	0.99	0.67	1.14
E _{fi} _prosumenci_GPZ1	val	1.86	1.19	1.11	1.13	1.15
E _{fi} _prosumenci_GPZ1	test	4.4	5.27	6.52	5.28	4.44
E _{fi} _prosumenci_GPZ2	train	3.09	1.07	1.99	0.8	1.91
E _{fi} _prosumenci_GPZ2	val	3.2	2.08	2.07	2.04	2.03
E _{fi} _prosumenci_GPZ2	test	4.85	3.97	4.51	4.05	4.97
E _{fi} _GPZ1	train	11.06	2.43	3.73	2.36	3.68
E _{fi} _GPZ1	val	9.84	3.89	3.99	3.83	4.12
E _{fi} _GPZ1	test	9.88	3.93	4.27	3.99	4.53
E _{fi} _GPZ2	train	8.82	2.16	3.7	2.18	3.67
E _{fi} _GPZ2	val	8.06	3.71	3.85	3.71	3.92
E _{fi} _GPZ2	test	8.11	3.64	3.98	3.63	5.3
E _{fi} _superobszaru	train	17.74	4.69	5.7	3.79	5.65
E _{fi} _superobszaru	val	15.72	5.64	5.96	5.72	6.17
E _{fi} _superobszaru	test	15.96	5.74	6.27	5.7	6.33
E _{RESm} _GPZ1	train	27.65	7.5	8.05	7.68	8.18
E _{RESm} _GPZ1	val	24.96	8.84	8.59	9.07	8.58
E _{RESm} _GPZ1	test	24.64	8.7	8.59	9.03	9.07
E _{RESm} _GPZ2	train	21.69	6.96	6.9	5.96	6.76
E _{RESm} _GPZ2	val	19.17	6.85	6.7	6.95	6.68
E _{RESm} _GPZ2	test	19.71	7.19	7.28	7.01	7.02
E _{RESm} _WN	train	24.91	7.22	7.37	6.71	7.51
E _{RESm} _WN	val	21.92	7.67	7.43	7.69	7.34
E _{RESm} _WN	test	22.3	7.65	7.66	7.61	7.55



Zestawienie wybranych przebiegów prognoz dla E_{fi}_prosum_GPZ1, pierwszy zbiór danych

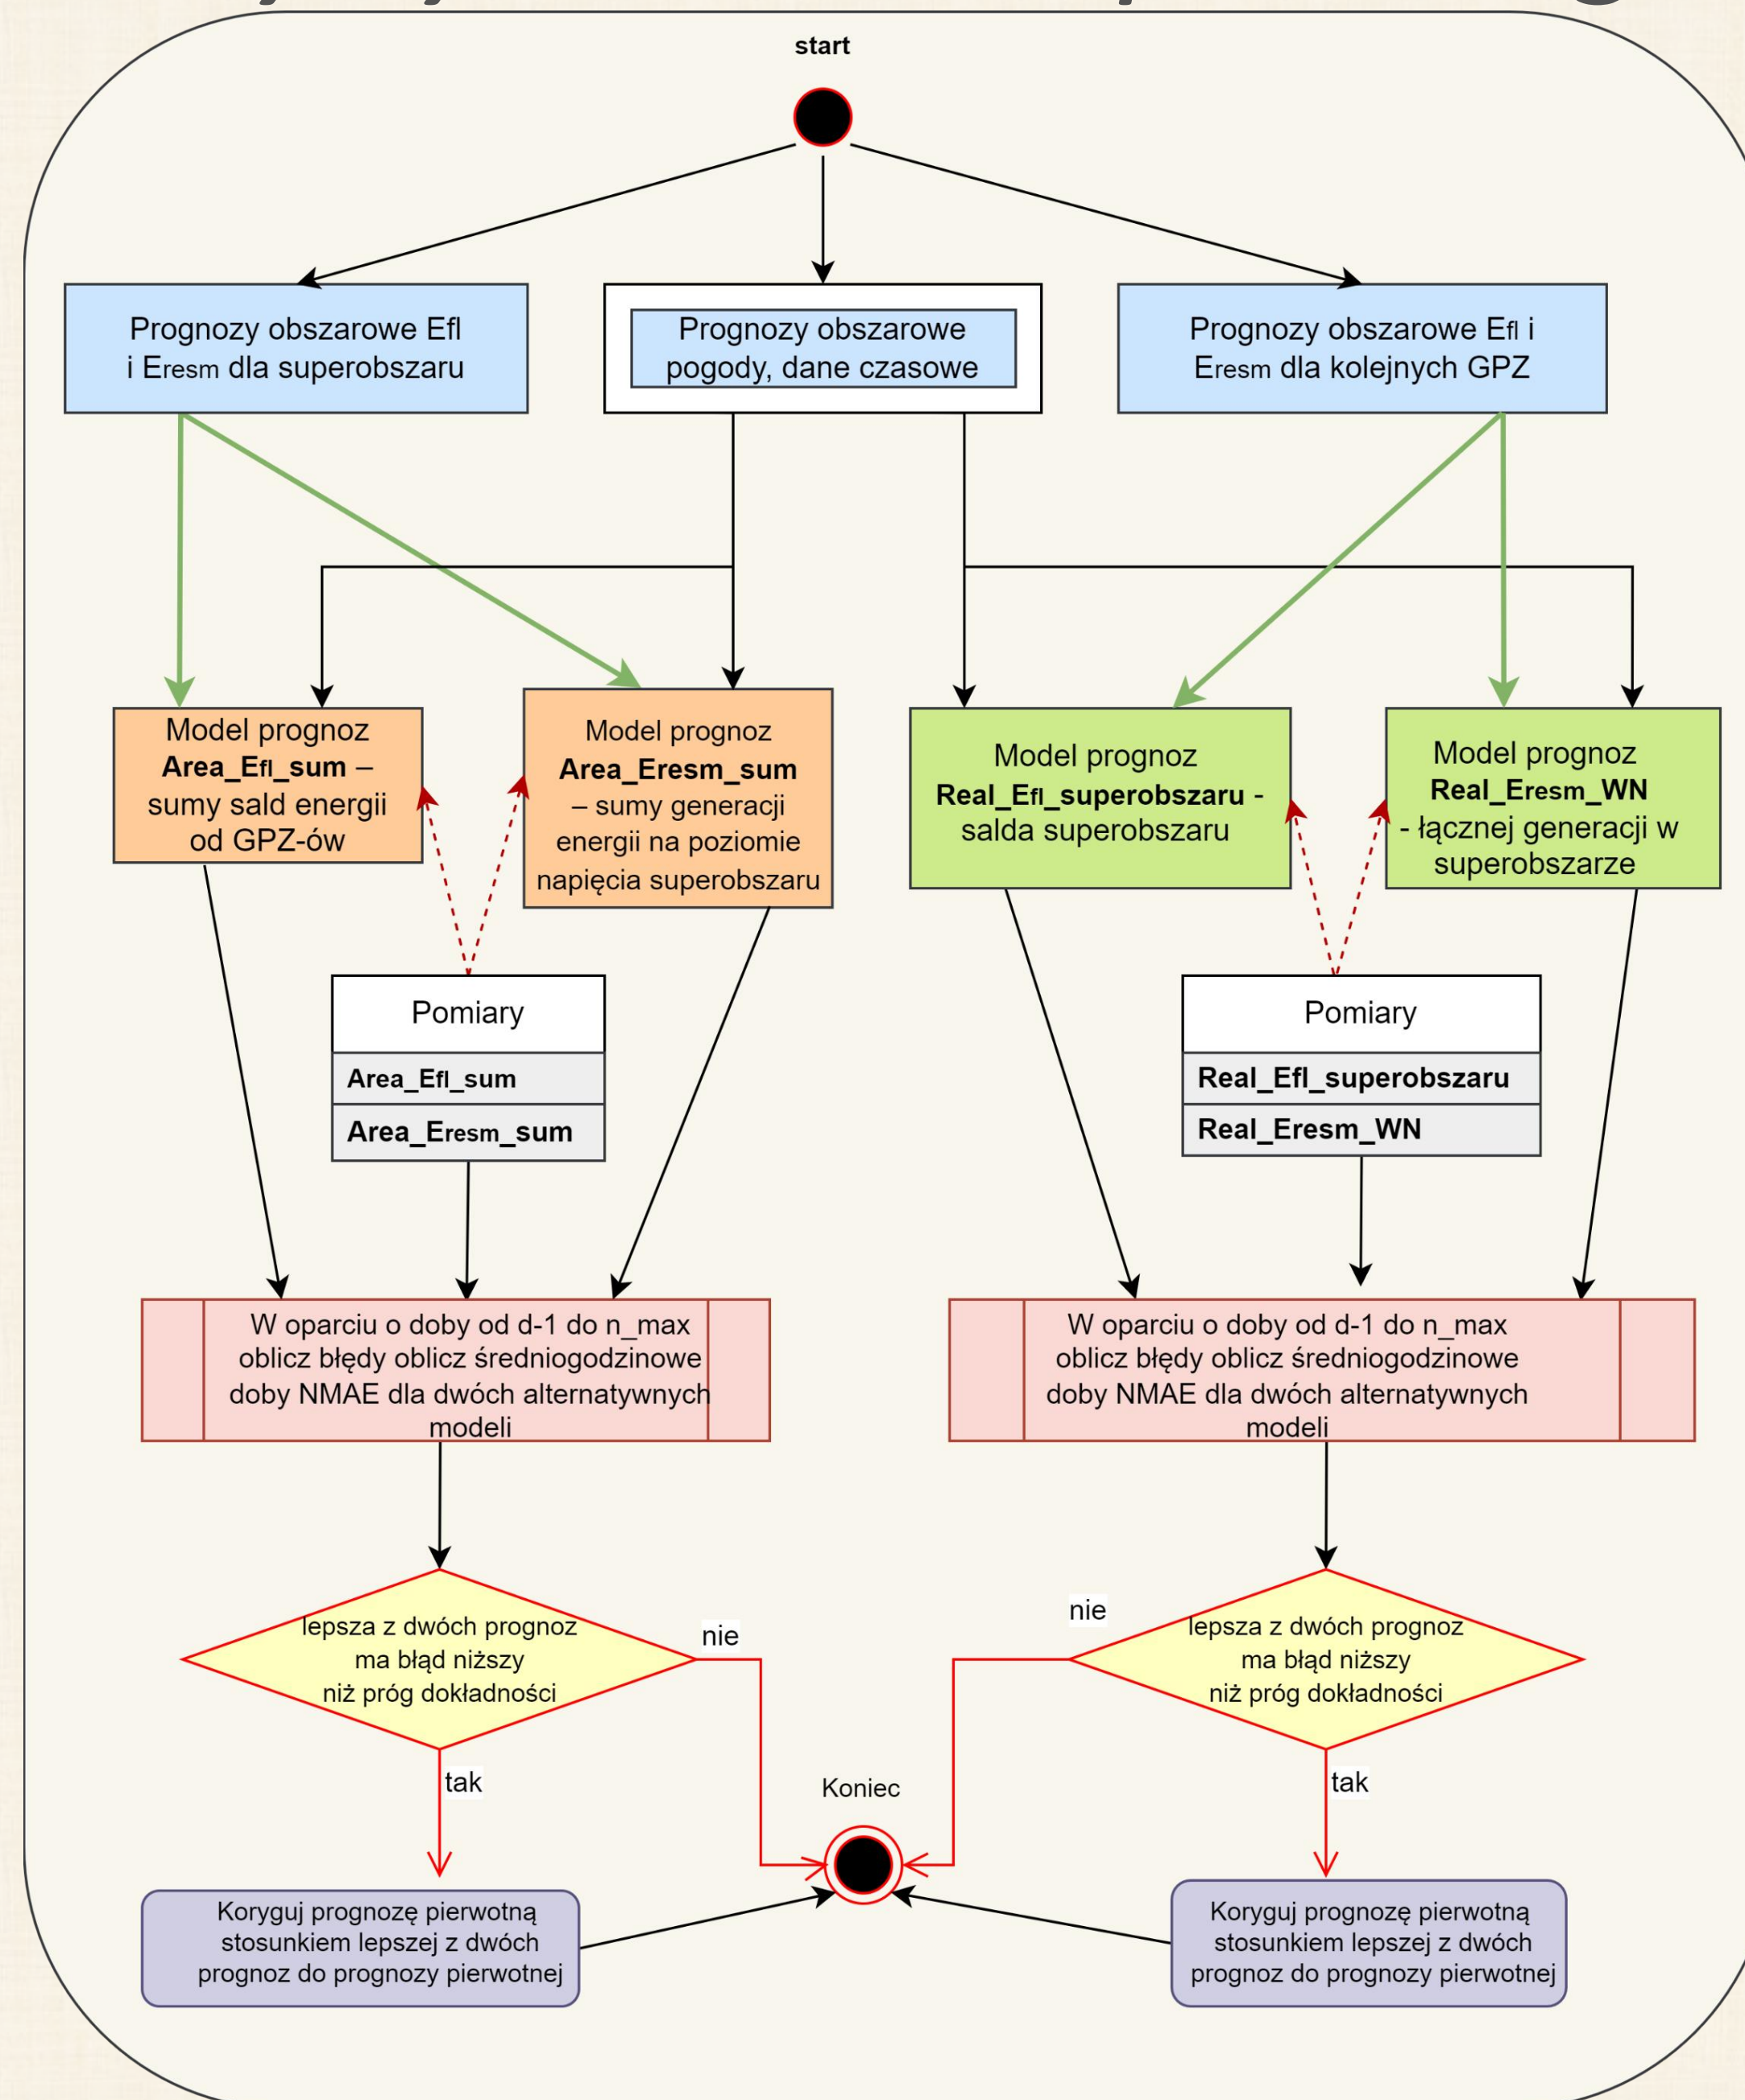
Wyniki prognoz – drugi zbiór danych

zmienna	Typ	Metoda naiwna	prognozy punktowe		prognozy obszarowe	
		NMAE [%]	NMAE [%] XGboost	NMAE [%] LSTM	NMAE [%] XGboost	NMAE [%] LSTM
E _{fl} _GPZ1	train	6.82	2.14	2.51	1.81	2.53
E _{fl} _GPZ1	val	6.36	3.01	2.97	2.99	2.88
E _{fl} _GPZ1	test	7.51	4.11	4.29	4.37	4.2
E _{fl} _GPZ2	train	12.07	7.78	8.05	8.07	7.96
E _{fl} _GPZ2	val	10.54	7.9	7.68	7.86	7.6
E _{fl} _GPZ2	test	11.82	8.58	8.61	8.4	8.69
E _{fl} _GPZ3	train	15.15	10.56	10.69	11.45	10.32
E _{fl} _GPZ3	val	14.76	11.41	10.33	11.46	10.41
E _{fl} _GPZ3	test	16.37	16.07	14.75	16.02	16.22
E _{fl} _GPZ4	train	9.51	5.29	5.93	4.81	5.98
E _{fl} _GPZ4	val	9.13	6.49	6.42	6.54	6.44
E _{fl} _GPZ4	test	9.45	6.01	5.88	6.23	5.98
E _{fl} _superobszaru	train	13.42	9.42	9.11	7.96	9.65
E _{fl} _superobszaru	val	12.25	9.18	9	9.26	8.88
E _{fl} _superobszaru	test	13.14	10.43	10.81	11.86	10.55
E _{resm} _GPZ1_FW1	train	22.6	6.07	7.27	6.21	7.32
E _{resm} _GPZ1_FW1	val	21.19	7.52	7.19	7.63	7.46
E _{resm} _GPZ1_FW1	test	24.89	8.95	8.66	9.66	9.28
E _{resm} _GPZ1_FW2	train	20.32	5.33	6.36	3.82	6.91
E _{resm} _GPZ1_FW2	val	18.83	6.26	5.88	6.43	6.05
E _{resm} _GPZ1_FW2	test	24.32	9.04	8.77	10.14	9.5
E _{resm} _GPZ2	train	7.7	3.08	3.9	1.96	3.86
E _{resm} _GPZ2	val	7.6	4.36	4.44	4.2	4.36
E _{resm} _GPZ2	test	7.49	4.12	3.96	4.12	4.24
E _{resm} _GPZ4	train	8.03	1.77	4.28	2.18	4.1
E _{resm} _GPZ4	val	7.71	4.46	4.62	4.31	4.47
E _{resm} _GPZ4	test	7.77	4.56	4.32	4.63	4.08
E _{resm} _WN	train	17.74	4.7	5.65	3.19	5.96
E _{resm} _WN	val	16.83	6.09	5.81	6.01	6.01
E _{resm} _WN	test	20.36	7.42	7.66	8.32	8.03



Zestawienie wybranych przebiegów prognoz dla E_{fl}_GPZ1 (góra) oraz E_{fl}_GPZ3(dół), drugi zbiór danych

Schemat blokowy systemu eksperckiego



Wyniki systemu korekt prognoz przepływów – pierwszy komplet danych

15

Miara [pp lub %]	Zakres	$E_{\alpha_GPZ1_new}$	$E_{\alpha_GPZ2_new}$	$E_{RESm_GPZ1_new}$	$E_{RESm_GPZ2_new}$	$E_{\alpha_superobszaru_new}$	$E_{RESm_WN_new}$	$Homog_E_{RESm_GPZ1_new}$
pp	train	0,29	0,21	0,43	0,36	0,03	-0,11	0,00
pp	val	0,32	0,17	-0,09	-0,05	0,01	0,15	0,00
pp	test	0,27	0,14	0,01	0,03	-0,01	0,10	0,00
%	train	0,04	0,09	-5,58	-5,94	-0,87	3,3	-9,44
%	val	0,03	0,13	2,43	2,19	1,26	0,14	3,62
%	test	0,13	0,00	1,36	0,62	1,00	0,11	1,74

Uzysk w punktach procentowych systemu warunkowego do systemu prostego oraz uzysk procentowy względny najlepszego wyniku systemu (prostego lub warunkowego) do prognozy pierwotnej.

Wyniki systemu korekt prognoz przepływów – drugi komplet danych

16

Uzysk w punktach procentowych systemu warunkowego do systemu prostego oraz uzysk procentowy względny najlepszego wyniku systemu (prostego lub warunkowego) do prognozy pierwotnej.

Miara [pp lub %]	Zakres	$E_{R_GPZ1_new}$	$E_{R_GPZ2_new}$	$E_{R_GPZ3_new}$	$E_{R_GPZ4_new}$	$E_{R_superobszaru_new}$	$E_{RESm_GPZ1_FW1_new}$	$E_{RESm_GPZ1_FW2_new}$	$E_{RESm_GPZ2_new}$	$E_{RESm_GPZ4_new}$	$E_{RESm_WN_new}$	$Homog_E_{R_GPZ3_new}$	$Homog_E_{RESm_WN_new}$
pp	train	0,21	0,26	0,16	0,44	-0,55	0,15	0,23	0,78	0,77	-0,01	0,00	0,00
pp	val	0,32	-0,08	-0,15	0,49	-0,23	0,19	0,15	0,56	0,53	-0,02	0,00	0,00
pp	test	0,83	0,35	-0,10	1,66	0,77	0,37	0,38	0,86	0,83	0,09	0,00	0,00
%	train	0,00	0,10	-1,37	0,00	3,01	0,11	0,12	0,00	0,00	3,50	-4,35	7,71
%	val	0,00	0,27	1,55	0,00	4,39	0,07	0,04	0,00	0,00	2,65	2,13	5,96
%	test	0,02	0,21	0,87	0,00	0,82	0,01	0,11	0,00	0,00	2,22	1,28	4,87

System rozdziału salda energii super obszaru na obszary 17

Trzy warianty modeli rozdziału mocy:

Prosty liniowy – OLS (MNK)

Złożony liniowy – Regresja liniowa

Złożony nieliniowy LSTM

Wariant prosty: tylko skalowanie zmiennej wejściowej współczynnikiem

Regresja liniowa: 3 różne warianty zmiennych pogodowych na każdą analizowaną zmienną wyjścia

-> 12 modeli dla zbioru danych I, 24 modele dla zbioru danych II

LSTM: zmienne jak dla regresji liniowej x 48 kombinacji hiperparametrów na każdą analizowaną zmienną wyjścia -> 576 modeli dla zbioru danych I, 1152 modele dla zbioru danych II,

Cel: mapowanie prognozy zmiennej superobszarowej na zmienną obszarową

Benchmark: oryginalna prognoza obszarowa, metoda naiwna

System rozdziału salda energii superobszaru na obszary – wyniki dla 1 zbioru danych i najlepszej metody

18

Zmienna	LSTM, z pełną pogodą			LSTM, tylko z danymi wiatrowymi			LSTM, tylko z danymi słonecznymi		
	train	val	test	train	val	test	train	val	test
<i>naive_pred_E_{fl}_GPZ1</i>	11,06	9,84	9,86						
<i>prognosis_area_xgb_E_{fl}_GPZ1</i>	2,36	3,83	3,99						
<i>estim_real_E_{fl}_GPZ1</i>	4,01	5,01	5,05	3,99	5,17	5,10	4,44	5,17	5,27
<i>naive_pred_E_{fl}_GPZ2</i>	8,82	8,06	8,09						
<i>prognosis_area_xgb_E_{fl}_GPZ2</i>	2,18	3,71	3,63						
<i>estim_real_E_{fl}_GPZ2</i>	3,97	5,35	5,00	3,92	5,36	5,02	4,70	5,57	5,11
<i>naive_pred_E_{RESm}_GPZ1</i>	27,65	24,96	24,58						
<i>prognosis_area_xgb_E_{RESm}_GPZ1</i>	7,68	9,06	9,01						
<i>estim_real_E_{RESm}_GPZ1</i>	8,16	8,58	8,70	8,25	8,58	8,53	8,76	8,84	9,14
<i>naive_pred_E_{RESm}_GPZ2</i>	21,69	19,17	19,65						
<i>prognosis_area_xgb_E_{RESm}_GPZ2</i>	5,96	6,95	7,00						
<i>estim_real_E_{RESm}_GPZ2</i>	6,78	6,87	7,08	6,85	6,87	6,92	7,32	6,85	7,39

System rozdziału salda energii superobszaru na obszary – zbiór danych II i najdokład. metoda

19

Zmienna	LSTM, z pełną pogodą			LSTM, tylko z danymi wiatrowymi			LSTM, tylko z danymi słonecznymi		
	train	val	test	train	val	test	train	val	test
<i>naive_pred_E_{fl}-GPZ1</i>	6,82	6,36	7,51						
<i>prognosis_area_lstm_E_{fl}-GPZ1</i>	2,53	2,88	4,20						
<i>estim_real_E_{fl}-GPZ1</i>	9,34	9,54	12,33	10,94	10,93	13,29	10,09	10,09	12,40
<i>naive_pred_E_{fl}-GPZ2</i>	12,07	10,54	11,82						
<i>prognosis_area_lstm_E_{fl}-GPZ2</i>	7,96	7,60	8,69						
<i>estim_real_E_{fl}-GPZ2</i>	8,55	7,96	8,77	8,73	7,93	8,68	8,58	7,96	8,46
<i>naive_pred_E_{fl}-GPZ3</i>	15,15	14,76	16,36						
<i>prognosis_area_lstm_E_{fl}-GPZ3</i>	10,32	10,41	16,22						
<i>estim_real_E_{fl}-GPZ3</i>	14,02	10,93	18,13	13,93	11,02	18,11	12,93	10,98	17,59
<i>naive_pred_E_{fl}-GPZ4</i>	9,51	9,13	9,45						
<i>prognosis_area_lstm_E_{fl}-GPZ4</i>	5,98	6,44	5,98						
<i>estim_real_E_{fl}-GPZ4</i>	6,41	6,97	6,65	7,33	8,27	9,66	6,74	7,14	6,71
<i>naive_pred_E_{RESm}-GPZ1_FW1</i>	22,60	21,19	24,89						
<i>prognosis_area_lstm_E_{RESm}-GPZ1_FW1</i>	7,30	7,43	8,98						
<i>estim_real_E_{RESm}-GPZ1_FW1</i>	7,55	7,84	9,38	7,54	7,82	9,27	7,83	8,02	9,86
<i>naive_pred_E_{RESm}-GPZ1_FW2</i>	20,32	18,83	24,32						
<i>prognosis_area_lstm_E_{RESm}-GPZ1_FW2</i>	6,90	6,05	9,26						
<i>estim_real_E_{RESm}-GPZ1_FW2</i>	6,79	6,37	9,54	6,72	6,40	9,80	7,04	6,60	9,94
<i>naive_pred_E_{RESm}-GPZ2</i>	7,70	7,60	7,48						
<i>prognosis_area_xgb_E_{RESm}-GPZ2</i>	1,95	4,18	4,12						
<i>estim_real_E_{RESm}-GPZ2</i>	3,95	4,68	4,71	4,98	5,96	7,23	4,33	5,02	4,66
<i>naive_pred_E_{RESm}-GPZ4</i>	8,03	7,71	7,77						
<i>prognosis_area_xgb_E_{RESm}-GPZ4</i>	2,18	4,31	4,61						
<i>estim_real_E_{RESm}-GPZ4</i>	4,47	4,95	5,04	5,34	6,46	7,79	4,95	5,31	4,82

- *Dokładność prognoz obszarowych jest akceptowalna, ale silnie zależny od czynników lokalnych oraz występowania sterowania*
- *Istnieją obiekty trudnoprognozowalne. Można to próbować rozwiązać postprocessingiem prognoz i zastosowaniem metod o krótkim buforze prognoz.*
- *Uzysk systemu korekt prognoz obszarowych nie przekracza 5 % i jeśli występuje wynosi zwykle ok. 1%*
- *Mapowanie prognoz z superobszaru na obszary składowe może stanowić rozwiązanie dla problemów braków danych wejściowych, awarii silnika prognostycznego, ataków na serwer. Może też służyć do osiągnięcia zgrubnych wielkości prognoz.*

Dziękuję za uwagę

