

Kryteria jakości prognoz - praktyczne implikacje stosowanych miar

dr hab. inż. Dariusz Baczyński, prof. uczelni
dr hab. inż. Paweł Piotrowski, prof. uczelni
dr inż. Marcin Kopyt

**Politechnika
Warszawska**

22 kwietnia 2026 roku



Czy prognozowanie jest ważne?

- Bilansowanie systemowe
- Planowanie pracy sieci
- Obrót energią elektryczną
- Planowanie rozwoju
- itp..




=




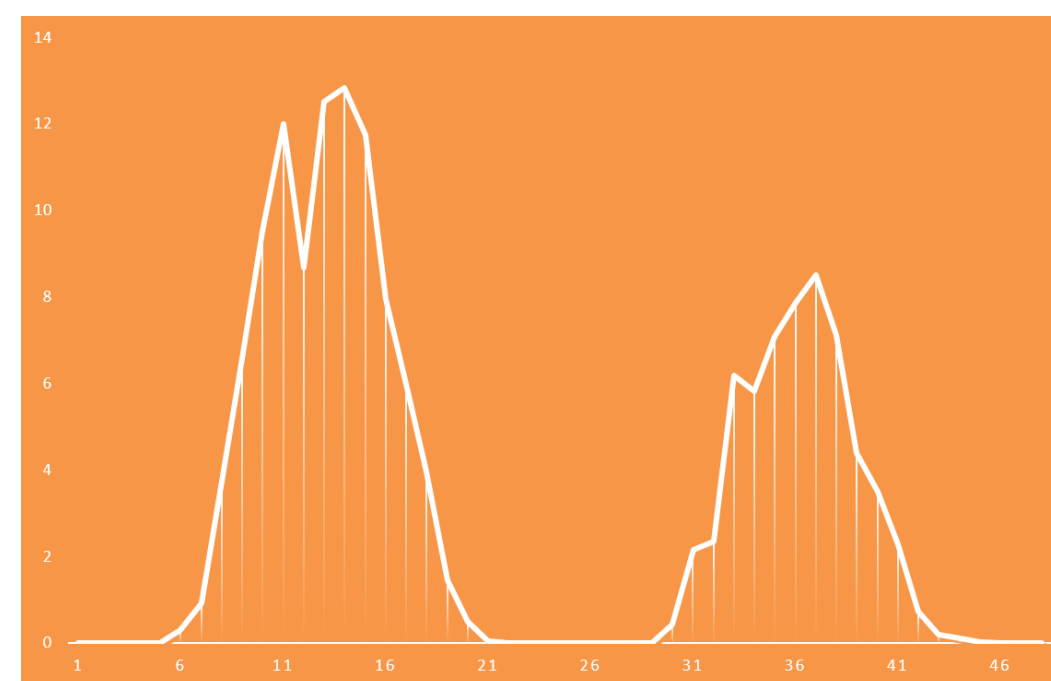

Jakość prognoz

Zapotrzebowanie mocy KSE


Okres: 2026-04-18



Dla rzetelnego podejmowania decyzji, niezależnie od celu, oprócz samej prognozy istotna jest także informacja o jej spodziewanej lub typowej „jakości”. Dlatego ważnym jest określenie „jakości” prognozy, która to informacja może być wykorzystana do porównywania różnych prognoz oraz szacowania ryzyka związanego z użyciem prognozy.



Ex-post i ex-ante



Ex-post – podstawowe miary dla pojedynczego punktu

Zakładając, że:

y_t - rzeczywista wartość zmiennej prognozowanej y w chwili t ,

y_t^* - prognozowana wartość zmiennej y w chwili t .

$$E = y_t - y_t^*$$

E (*Error*) – najprostszы błąd bezwzględny

$$AE = |y_t - y_t^*|$$

AE (*Absolute Error*) – moduł błędu bezwzględnego

$$APE = \left| \frac{y_t - y_t^*}{y_t} \right| * 100\%$$

APE (*Absolute Percentage Error*) – moduł błędu procentowego

$$SE = (y_t - y_t^*)^2$$

SE (*Square Error*) – kwadrat błędu

$$NMAE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_i^*|}{C_{norm}}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*|$$

$$sMdAPE = \text{median}_{i=1 \dots n} \left(\frac{|y_i - y_i^*|}{y_i + y_i^*} * 200\% \right)$$

Menzeria (miar błędów)

$$MaxAE = \max_{i=1 \dots n} |y_i - y_i^*|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2}$$

względne <> bezwzględne
znormalizowane

Kryteria podstawowe dla okresu - bezwzględne

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*|$$

MAE (Mean Absolute Error)

$$ME = MBE = BIAS = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)$$

ME (Mean Error), MBE (Mean Bias Error), BIAS, obciążenie prognozy

$$MdAE = \text{median}_{i=1\dots n} |y_i - y_i^*|$$

MdAE (Median Absolute Error)

Kryteria dla okresu - bezwzględne

$$MaxAE = \max_{i=1\dots n} |y_i - y_i^*| \quad MaxAE \text{ (Maximum Absolute Error)}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2 \quad MSE \text{ (Mean Square Error)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2} \quad RMSE \text{ (Root Mean Square Error)}$$

Kryteria dla okresu – względne

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^*}{y_i} \right| * 100\% \quad MAPE \text{ (Mean Absolute Percentage Error)}$$

$$MdAPE = \text{median}_{i=1\dots n} \left(\left| \frac{y_i - y_i^*}{y_i} \right| * 100\% \right) \quad MdAPE \text{ (Median Absolute Percentage Error)}$$

$$sMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_i^*|}{y_i + y_i^*} * 200\% \quad sMAPE \text{ (Symmetric Mean Absolute Percentage Error)}$$

$$sMdAPE = \text{median}_{i=1\dots n} \left(\frac{|y_i - y_i^*|}{y_i + y_i^*} * 200\% \right) \quad sMdAPE \text{ (Symmetric Median Absolute Percentage Error)}$$

Kryteria podstawowe dla okresu – inna klasyfikacja

10

Podstawowa klasyfikacja zwykle dotyczy kwestii czy błąd jest bezwzględny czy względny ale można także wskazać inną klasyfikację – ze względu na rząd momentu błędu.

Najczęściej wyróżnia się kryteria związane z pierwszym rzędem momentu błędu (np. *MAE*, *BIAS*, *MAPE*) oraz z drugim rzędem (np. *MSE*, *RMSE*). Występują także miary związane z czwartym rzędem np. *RMQE*.

Kryteria dla okresu – znormalizowane

$$NMAE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_i^*|}{C_{norm}}$$

NMAE (Normalized Mean Absolute Error)

$$NBIAS = \frac{1}{n} \sum_{i=1}^n \frac{(y_i - y_i^*)}{C_{norm}}$$

NBIAS (Normalized BIAS) (lub NME, NMBE)

$$NMSE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - y_i^*}{C_{norm}} \right)^2$$

NMSE (Normalized Mean Square Error)

$$NRMSE = \frac{1}{C_{norm}} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2}$$

NRMSE (Normalized Root Mean Square Error)

Stosowanie tych miar pozwala porównywać jakość prognoz dla różnych obiektów.

Kryteria dla okresu – skumulowane

$$CE = \sum_{i=1}^n (y_i - y_i^*) \quad \text{błąd skumulowany } CE \text{ (Cumulative Error)}$$



$$CPE = \sum_{i=1}^n \left(\frac{y_i - y_i^*}{y_i} \right) * 100\% \quad CPE \text{ (Cumulative Percentage Error)}$$

$$CumRAEm = \frac{\sum_{i=1}^n |y_i - y_i^*|}{\sum_{i=1}^n |y_i - y_i^{*b}|} \quad CumRAEm \text{ (Cumulative Relative Absolute Error)}$$

Stosowanie tych miar pozwala analizować różne aspekty obciążenia prognozy a na wykresie przebieg i monotoniczność narastania błędu.

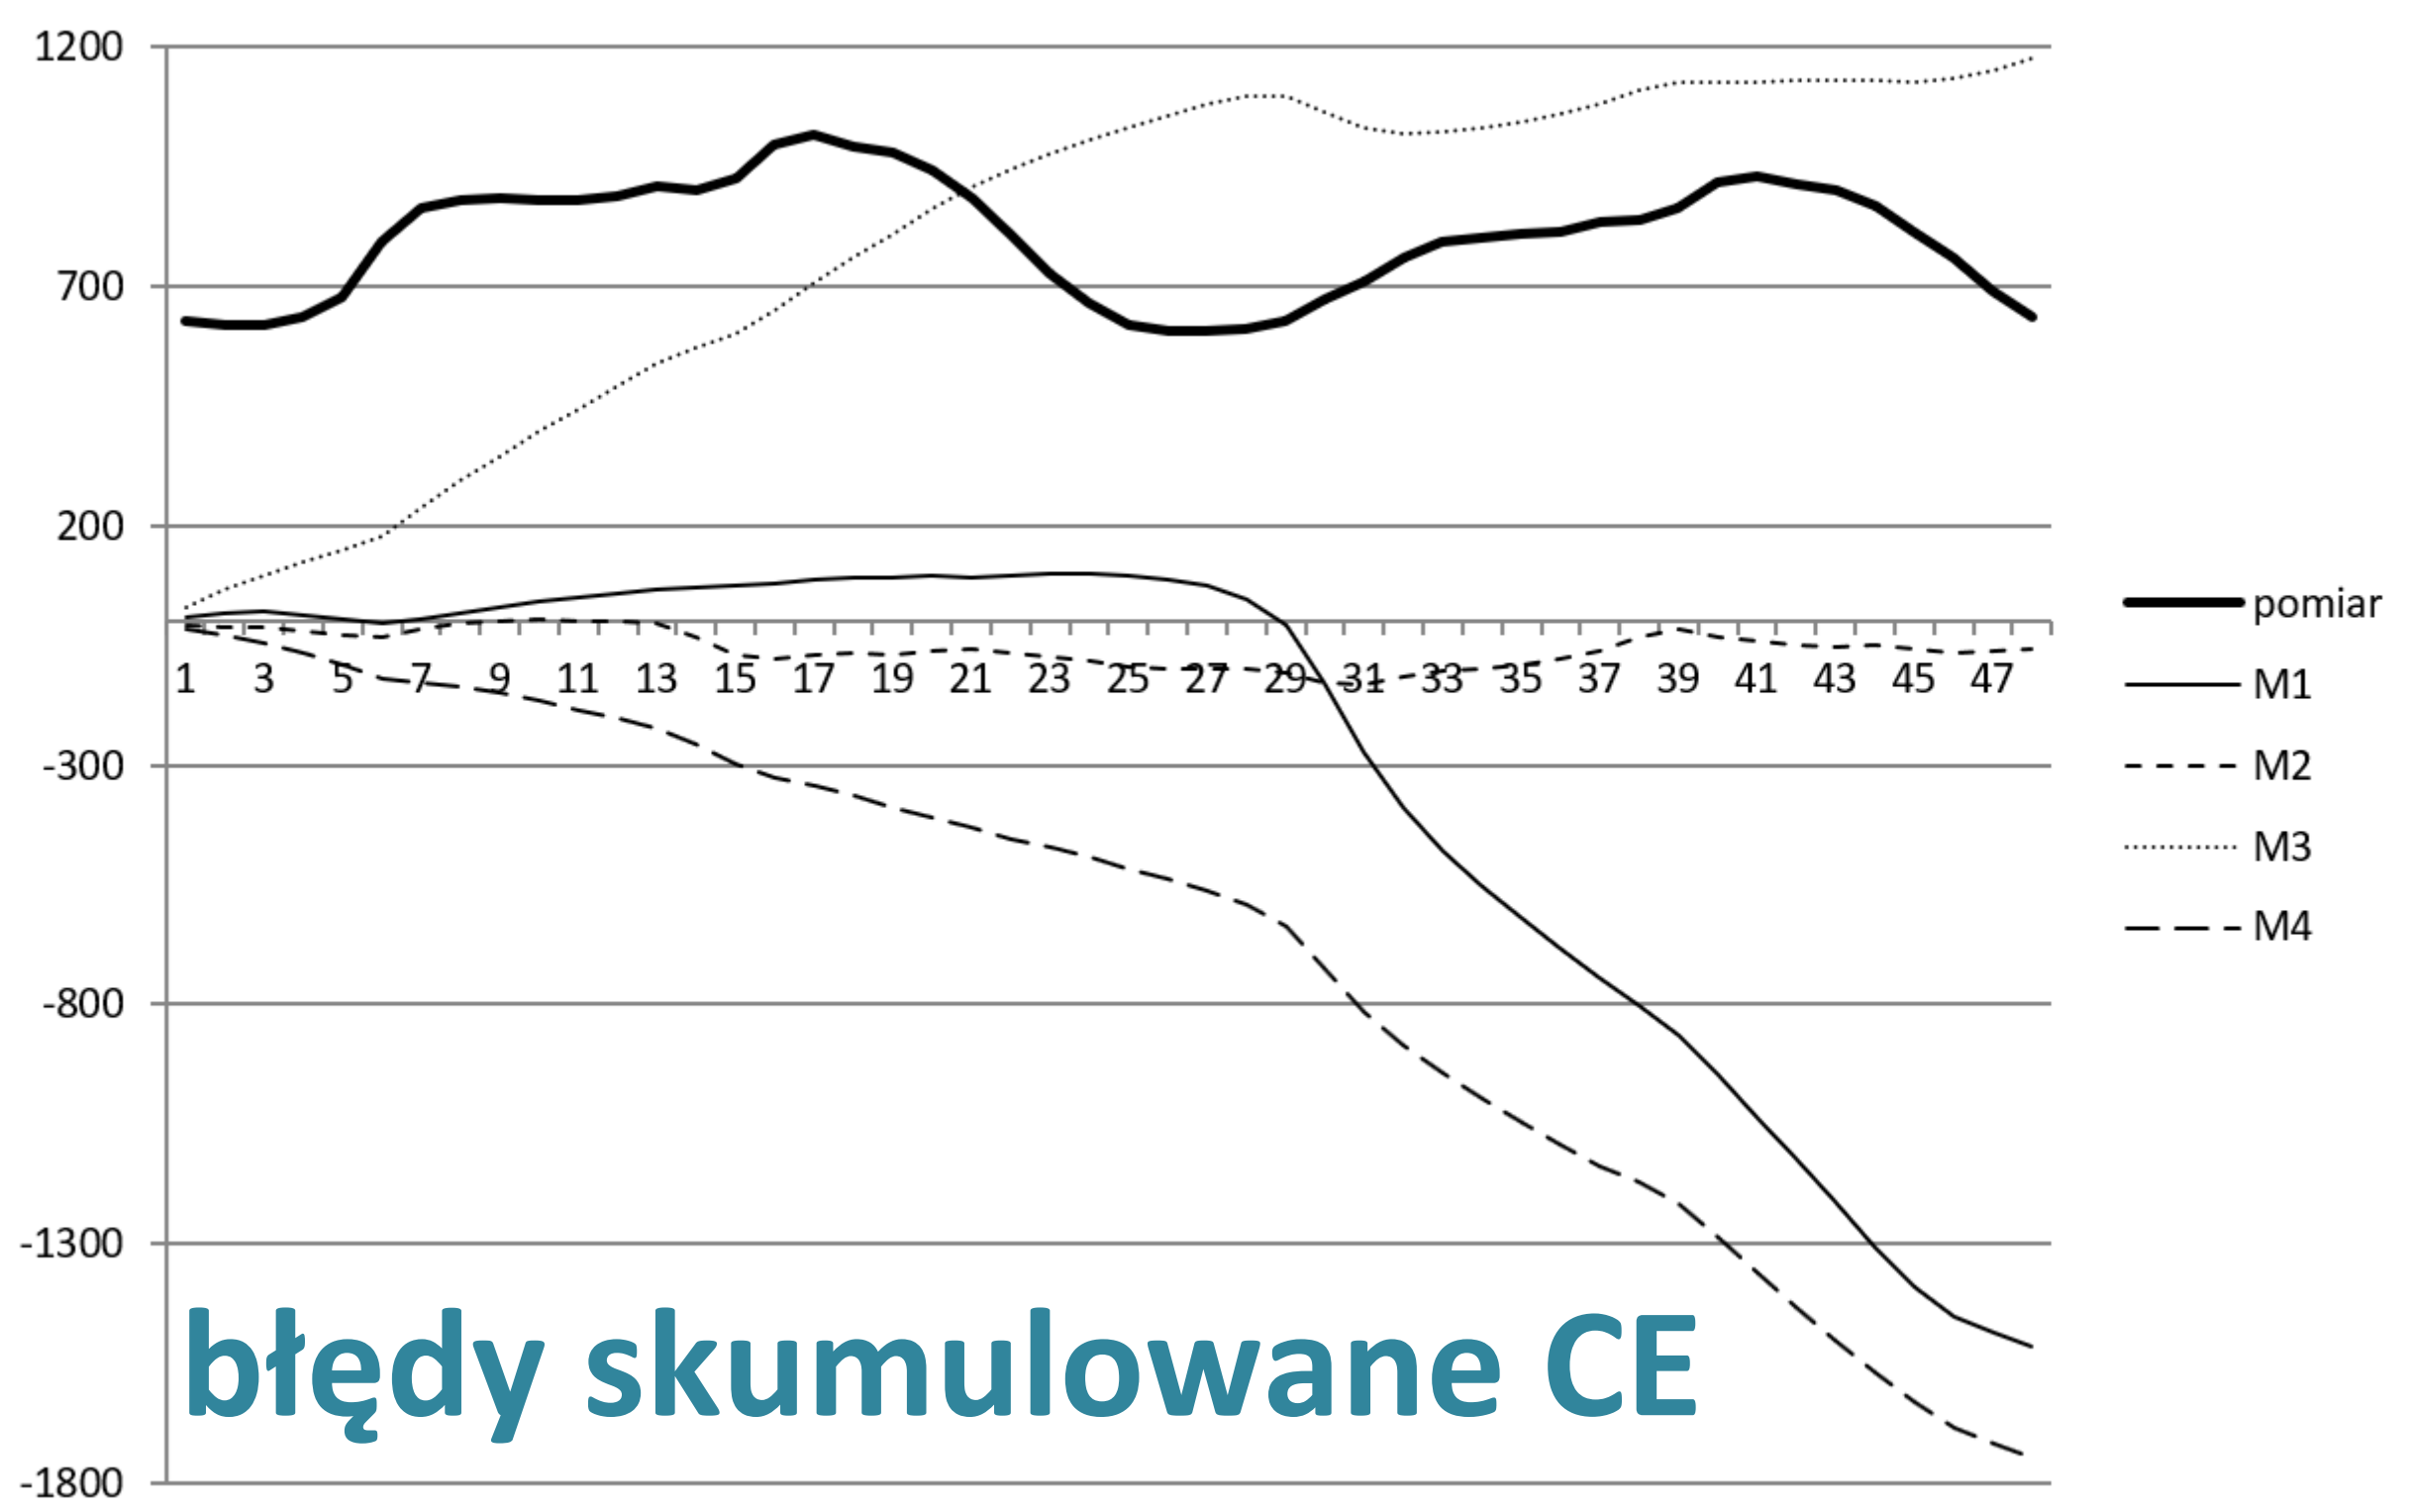
Kryteria dla okresu – skumulowane

błędy E



prognozy

- pomiar
- M1
- - - M2
- M3
- . - M4



błędy skumulowane CE

- pomiar
- M1
- - - M2
- M3
- . - M4

Kryteria dla okresu – porównawcze względem metody benchmarkowej (prognoza y_i^{*b})

$$MRAE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^*}{y_i - y_i^{*b}} \right| \quad MRAE \text{ (Mean Relative Absolute Error)}$$

$$MdRAE = \text{median}_{i=1 \dots n} \left| \frac{y_i - y_i^*}{y_i - y_i^{*b}} \right| \quad MdRAE \text{ (Median Relative Absolute Error)}$$

$$SS = \frac{1}{2} \left[\left(1 - \frac{nMAE}{nMAE_b} \right) + \left(1 - \frac{nRMSE}{nRMSE_b} \right) \right] \quad \text{Skill Score – SS}$$

$$PB(MAE) = 100\% * \frac{1}{k} \sum_{i=1}^k (I(MAE)) \quad PB(MAE) \text{ (Percent Better(MAE))}:$$

$$I(MAE) = \begin{cases} 0 & \text{jeżeli } MAE < MAE_b \\ 1 & \end{cases}$$

Kryteria dla okresu – rozrzut błędów – odchylenie standardowe

$$Std_AE = \sqrt{\frac{\sum_{i=1}^n (AE_i - MAE)^2}{n-1}}$$

Std_AE (Standard Deviation of Absolute Error)

$$Std_APE = \sqrt{\frac{\sum_{i=1}^n (APE_i - MAPE)^2}{n-1}}$$


Std_APE (Standard Deviation of Absolute Percentage Error)

Kryteria dla okresu – współczynnik korelacji liniowej Pearsona

$$R = \frac{cov(y_i, y_i^*)}{\sigma_{y_i} * \sigma_{y_i^*}} = \frac{\sum_{i=1}^n (y_i - \bar{y})(y_i^* - \bar{y}^*)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (y_i^* - \bar{y}^*)^2}}$$

Współczynnik korelacji liniowej Pearsona określa siłę związku pomiędzy dwoma szeregami czasowymi w sensie **współbieżności liniowej**, którą rozumie się tak, że przyrostowi jednego szeregu czasowego towarzyszy liniowo zależny przyrost drugiego szeregu. Jest on miarą unormowaną i przyjmuje wartości od -1 do +1. Wartości równe zero oznaczają brak korelacji pomiędzy szeregami.

Przykład – fragment OSD




Politechnika
Warszawska

	Prognozy			
kryterium	M1	M2	M3	M4
MAE [MW]	36,87	8,92	27,81	36,36
BIAS [MW]	-31,51	-1,17	24,47	-36,36
MdAE [MW]	11,32	7,14	29,07	26,69
AE95 [MW]	108,42	24,76	54,42	72,26
AE99 [MW]	132,14	34,32	58,05	89,27
MaxAE [MW]	143,97	37,73	59,66	91,43
MSE [MW]	2888,78	136,36	1089,78	1802,50
RMSE [MW]	53,75	11,68	33,01	42,46
RMQE [MW]	73,08	17,03	38,69	52,19
GMAE [MW]	16,40	6,11	16,24	30,30
MAPE [%]	4,68	1,11	3,47	4,61
MdAPE [%]	1,44	0,93	3,95	3,87
sMAPE [%]	4,46	1,11	3,54	4,47
sMdAPE [%]	1,45	0,94	4,03	3,79
NMAE [%]	3,07	0,74	2,32	3,03
NBIAS [%]	-2,63	-0,10	2,04	-3,03
NRMSE [%]	4,48	0,97	2,75	3,54
Std_AE [MW]	39,52	7,61	17,97	22,16
Std_APE [%]	5,09	0,89	2,03	2,84
Korelacja [-]	0,9403	0,9955	0,9841	0,9847

Przykład – turbina wiatrowa

dobrze warunki produkcji




Politechnika
Warszawska

	Prognozy			
kryterium	M1	M2	M3	M4
MAE [MW]	511.98	322.07	372.18	354.01
BIAS [MW]	264.58	35.41	193.11	125.57
MdAE [MW]	446.50	256.58	295.96	279.90
AE95 [MW]	1327.81	830.00	892.90	837.12
AE99 [MW]	1469.49	1013.34	968.55	874.67
MaxAE [MW]	1592.75	1111.96	976.06	882.86
MSE [MW]	404252.55	160218.95	208435.46	179817.78
RMSE [MW]	635.81	400.27	456.55	424.05
RMQE [MW]	828.89	538.88	575.16	528.09
GMAE [MW]	367.87	235.18	260.37	270.82
MAPE [%]	62.02	49.23	46.28	47.75
MdAPE [%]	45.44	30.34	36.23	32.15
sMAPE [%]	58.96	40.87	42.60	40.48
sMdAPE [%]	51.78	35.43	42.70	37.64
NMAE [%]	42.67	26.84	31.01	29.50
NBIAS [%]	22.05	2.95	16.09	10.46
NRMSE [%]	52.98	33.36	38.05	35.34
Std_AE [MW]	380.98	240.20	267.22	235.91
Std_APE [%]	56.28	66.27	48.65	55.32
Korelacja [-]	0.4076	0.7805	0.7626	0.7658

Przykład – turbina wiatrowa

zmiennie warunki produkcji



Politechnika
Warszawska

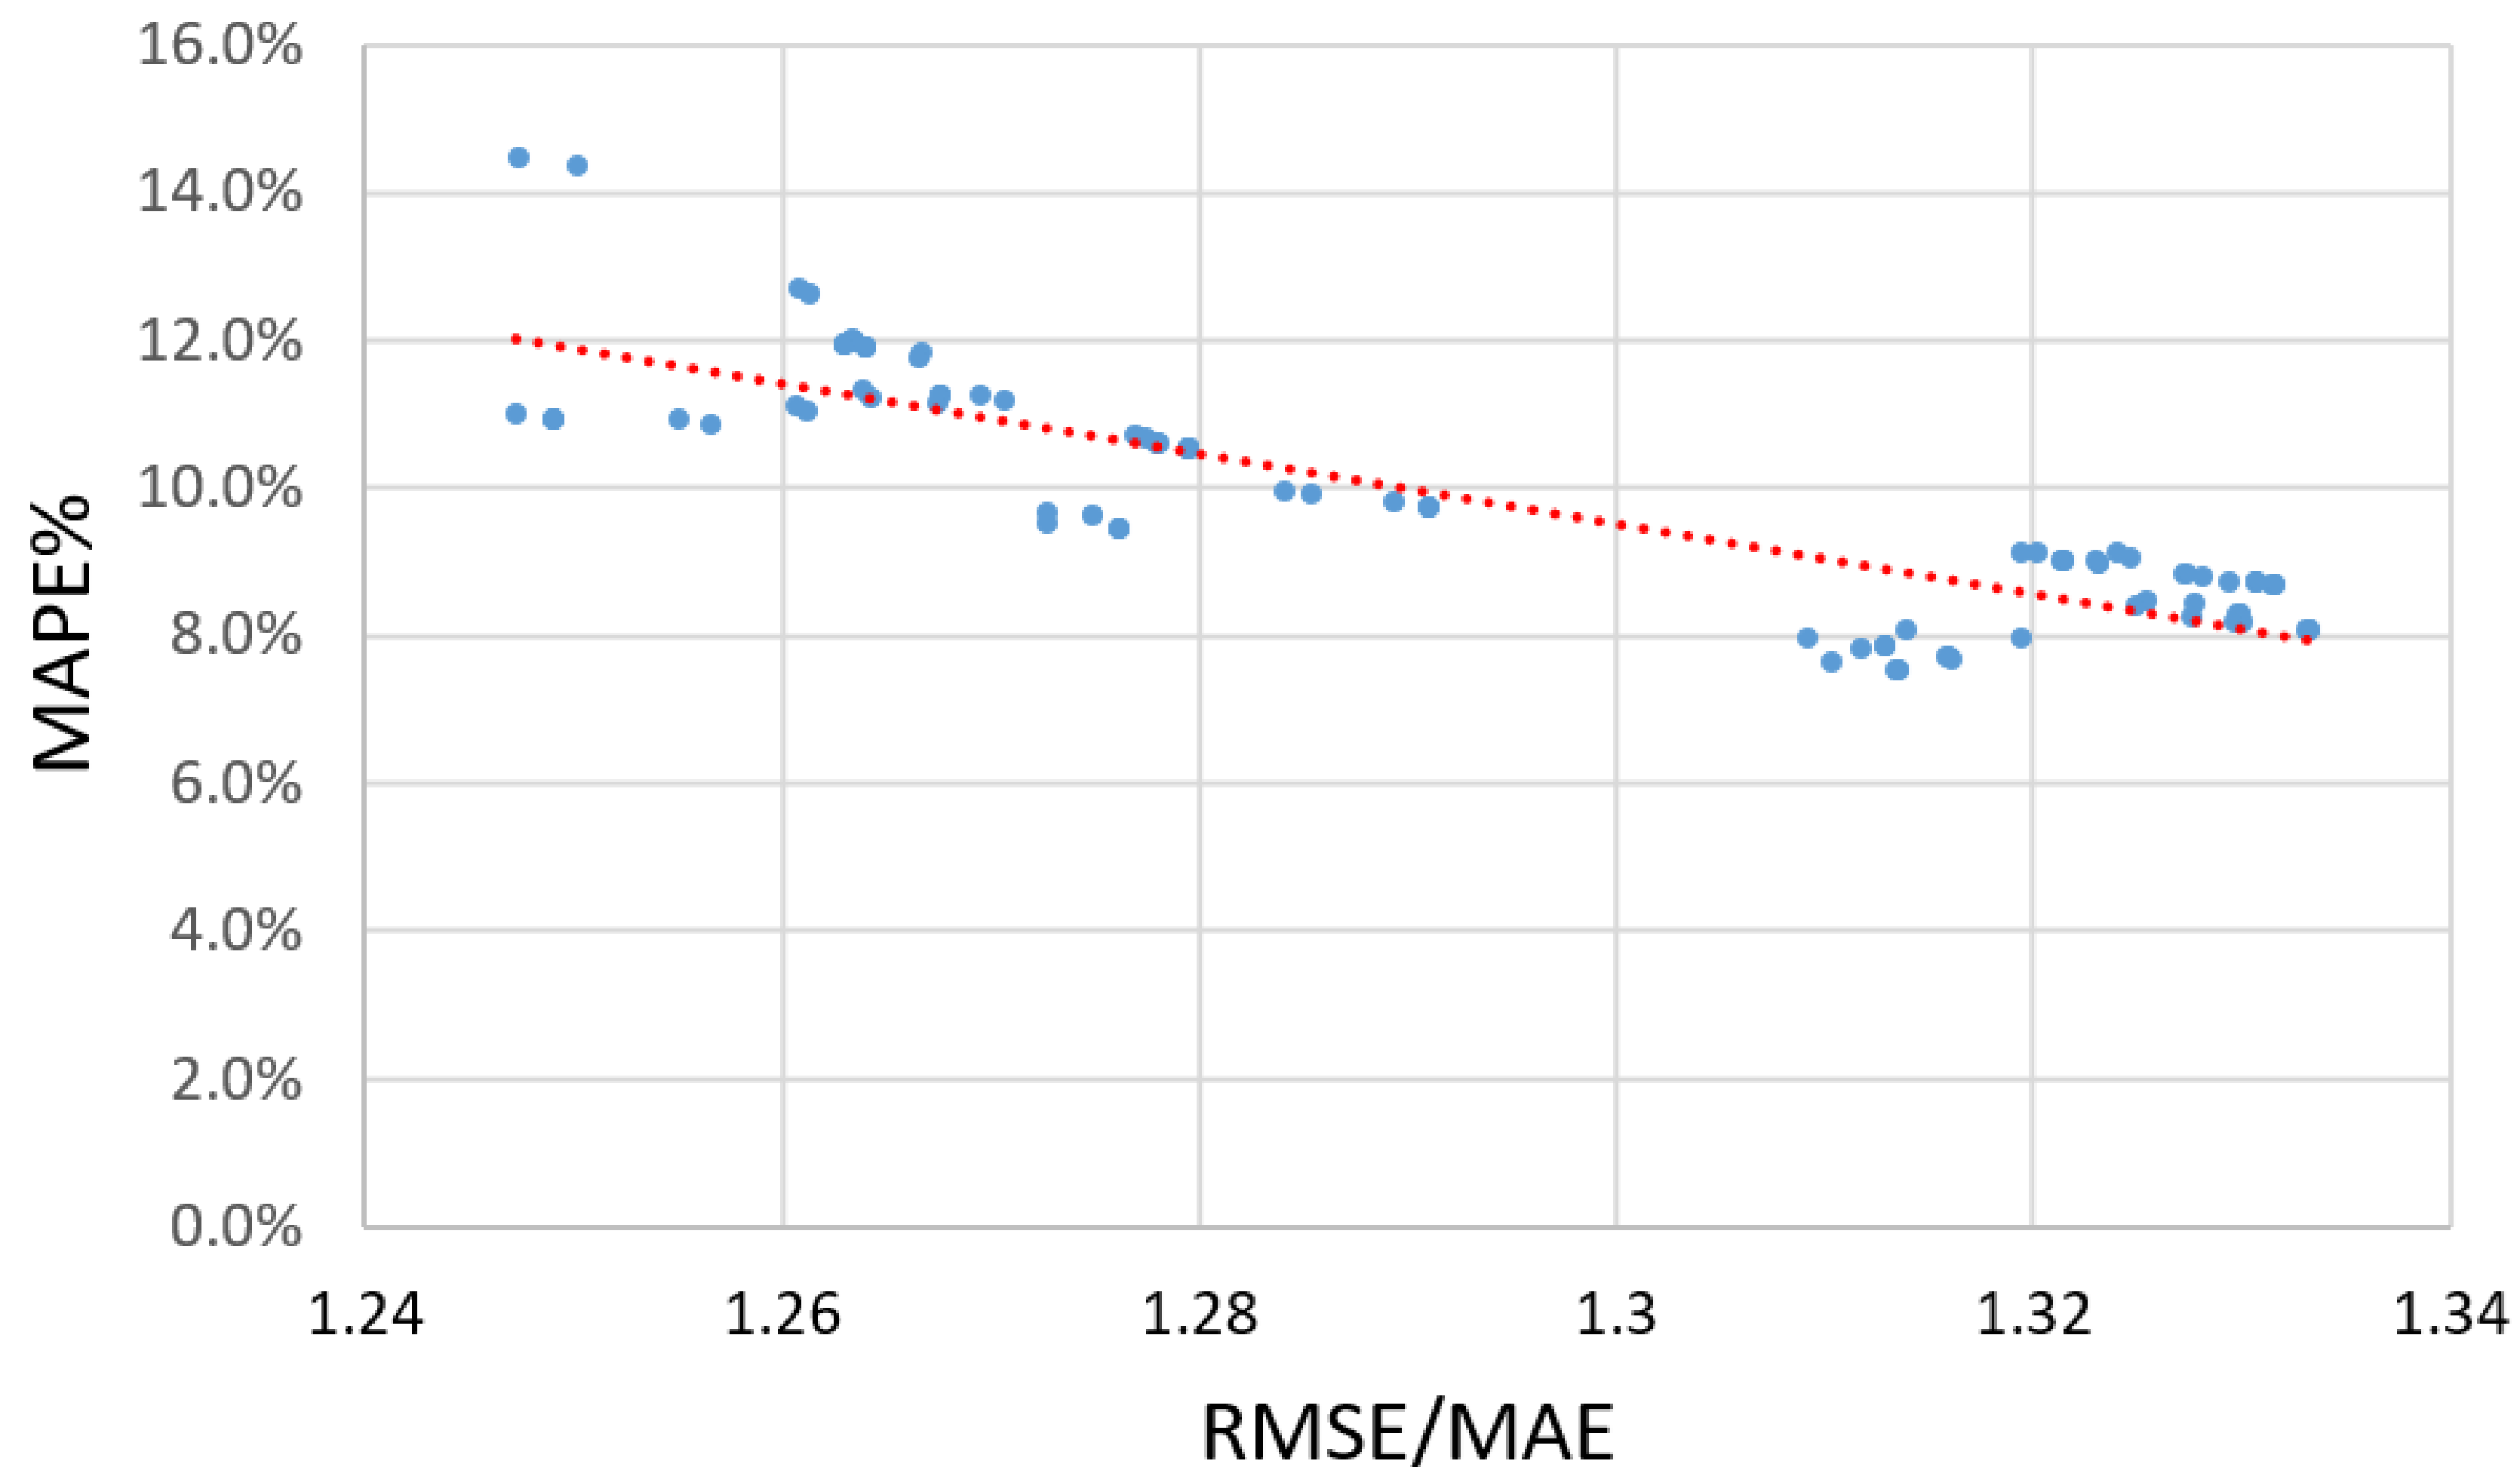
	Prognozy			
kryterium	M1	M2	M3	M4
MAE [MW]	805.81	553.97	617.86	608.92
BIAS [MW]	622.03	322.32	492.18	458.42
MdAE [MW]	629.63	296.02	277.13	258.11
AE95 [MW]	1734.85	1701.70	1642.92	1639.12
AE99 [MW]	1847.54	1851.09	1826.12	1822.13
MaxAE [MW]	1926.50	1926.50	1926.50	1926.50
MSE [MW]	1041982.37	598966.99	717186.96	690854.23
RMSE [MW]	1020.78	773.93	846.87	831.18
RMQE [MW]	1239.63	1063.16	1097.12	1084.09
GMAE [MW]	0 (błąd)	285.62	323.32	324.06
MAPE [%]	∞ (błąd)	∞ (błąd)	∞ (błąd)	∞ (błąd)
MdAPE [%]	∞ (błąd)	∞ (błąd)	∞ (błąd)	∞ (błąd)
sMAPE [%]	∞ (błąd)	114.98	119.84	118.18
sMdAPE [%]	∞ (błąd)	119.71	125.02	119.88
NMAE [%]	67.15	46.16	51.49	50.74
NBIAS [%]	51.84	26.86	41.01	38.20
NRMSE [%]	85.06	64.49	70.57	69.26
Std_AE [MW]	633.25	546.17	585.30	571.74
Std_APE [%]	∞ (błąd)	∞ (błąd)	∞ (błąd)	∞ (błąd)
Korelacja [-]	-0.2219	0.3686	0.2147	0.2222

Analiza miar błędów.

Prognozy cen energii elektrycznej (rynek włoski IPEX) – horyzont 1 doba.

Wizualizacja wyników różnych wariantów jednego modelu - regression splines decomposition (RSD)

Korelacja $R=-0,866$



Wnioski

1. „Nieidealne prognozy nieidealnych modeli” – **optymalizując jedno kryterium zwykle powodujemy pogarszanie innego kryterium.**
2. Dlatego ważne jest jasne postawienie **celu prognozy** (cel biznesowy) – i na tej podstawie dobór „kluczowego” lub „wiodącego” kryterium prognozy, które zostanie następnie użyte jako funkcja „straty” (celu) dla modelu prognostycznego.
3. Można także wykorzystać optymalizację wielokryterialną w celu zminimalizowania dwóch lub większej liczby kryteriów jednocześnie.
4. Bardzo ważny jest dobór właściwych miar jakości przy porównywaniu prognoz z różnych okresów czasowych dla jednego obiektów i dla różnych obiektów.

Dziękuję za uwagę