

Konferencja PTPIREE

Szacowanie i prognozowanie w sieciach elektroenergetycznych

22-23 kwietnia 2026 r., Warszawa

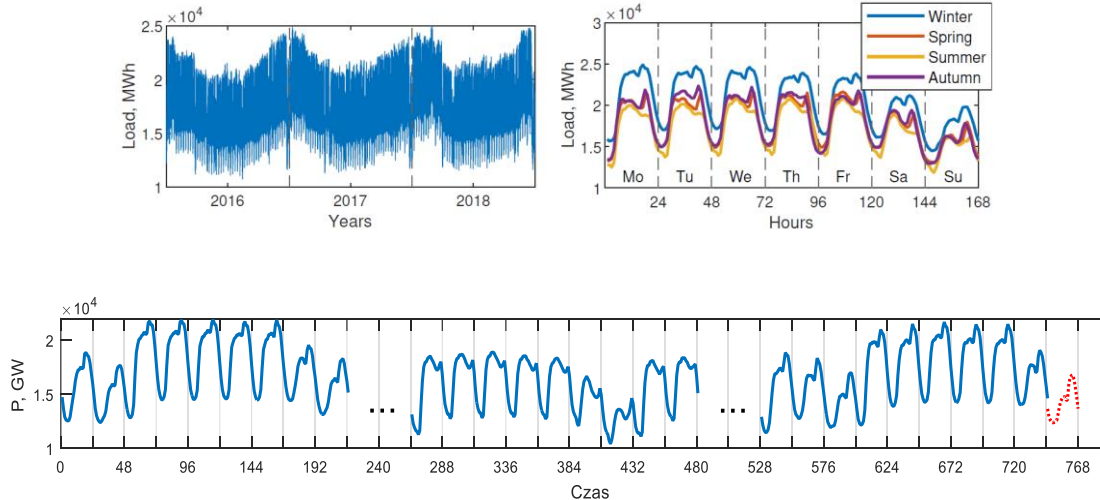
Prognozowanie obciążeń systemów elektroenergetycznych: Hybrydowe modele neuronowe – nowe mechanizmy i możliwości

Grzegorz Dudek, Sławek Smył, Paweł Pełka

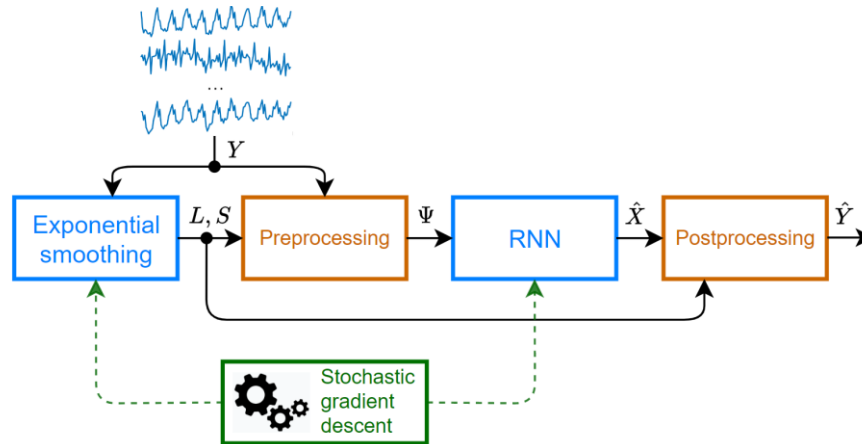
1. Motywacja
2. Problem prognostyczny
3. Budowa modeli hybrydowych
4. Modele ze ścieżką kontekstową
5. Modele probabilistyczne
6. Podsumowanie

- Prognozowanie zapotrzebowania na energię elektryczną jest kluczowe dla efektywnej i bezpiecznej pracy systemów elektroenergetycznych oraz funkcjonowania rynków energii
- Szeregi czasowe obciążeń charakteryzują się wysoką złożonością: nieliniowy trend, wielokrotna sezonowość, losowe fluktuacje
- Modele uczenia maszynowego umożliwiają wykrywanie wzorców i zależności w danych oraz ich ekstrapolację
- Rekurencyjne sieci neuronowe (RNN) dobrze modelują zależności czasowe
- Hybrydyzacja modeli pozwala łączyć ich zalety i upraszczać problem prognostyczny
- Nowoczesne metody uczenia maszynowego pozwalają włączyć do procesu uczenia różne mechanizmy i procedury, wbudowując je w model

Krótkoterminowe prognozowanie zapotrzebowania na energię elektryczną (STLF) – prognoza dobowego profilu obciążenia (24 godziny) na kolejny dzień na podstawie danych historycznych



Zwycięski model konkursu prognostycznego M4



- Smyl S.: *A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting*. *International Journal of Forecasting*, vol. 36(1), pp. 75-85, 2020.

Uczenie globalne (*cross-learning*)

Uczenie na wielu szeregach czasowych w celu uchwycenia wspólnych cech poszczególnych szeregów oraz ograniczenia przeuczenia

Trójpoziomowy *ensembling*

- **Poziom treningu:** Uśrednianie prognoz uzyskanych z L ostatnich epok treningowych
- **Poziom danych:** Uśrednianie prognoz z puli K modeli uczonych na różnych podzbiorach zbioru treningowego
- **Poziom modelu:** Uśrednianie prognoz z R niezależnych uruchomień puli K modeli z poziomu podzbiorów danych

ES-adRNN – hybrid exponential smoothing and dilated recurrent NN model with attention




Fig. 1. Block diagram of the proposed ES-adRNN forecasting model.

Uproszczony model multiplikatywny Holta-Wintersa:

$$l_{t,\tau} = \alpha_t \frac{z_\tau}{s_{t,\tau}} + (1 - \alpha_t)l_{t,\tau-1}$$
$$s_{t,\tau+168} = \beta_t \frac{z_\tau}{l_{t,\tau}} + (1 - \beta_t)s_{t,\tau}$$

Nowość: współczynniki wygładzania są adaptowane w każdym cyklu rekurencji t :

$$\alpha_{t+1} = \sigma(I\alpha + \Delta\alpha_t)$$
$$\beta_{t+1} = \sigma(I\beta + \Delta\beta_t)$$

gdzie σ to funkcja sigmoidalna, $I\alpha$, $I\beta$ to wartości stałe, a $\Delta\alpha_t$, $\Delta\beta_t$ to korekty wyznaczone przez adRNN

Przetwarzanie danych i definicja wejść RNN

Dane wejściowe i wyjściowe – *preprocessing* i *postprocessing*

$$\mathbf{x}_t^{in'} = [\mathbf{x}_t^{in}, \hat{\mathbf{s}}_t, \log_{10}(\bar{z}_t), \mathbf{d}_t^w, \mathbf{d}_t^m, \mathbf{d}_t^y]$$

$$x_\tau = \log \frac{z_\tau}{\bar{z}_t \hat{s}_{t,\tau}}$$


$$\hat{z}_\tau = \exp(\hat{x}_\tau) \bar{z}_t \hat{s}_{t,\tau}$$

gdzie:

$\hat{\mathbf{s}}_t$ - wektor sezonowy prognozowany przez model wykładniczego

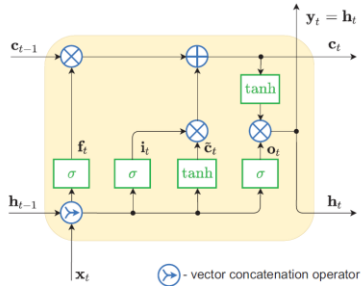
$\log_{10}(\bar{z}_t)$ - bieżący poziom szeregu czasowego

$\mathbf{d}_t^w, \mathbf{d}_t^m, \mathbf{d}_t^y$ - binarne wektory (*one-hot*) kodujące odpowiednio: dzień tygodnia, dzień miesiąca oraz tydzień roku




RNN: komórki rekurencyjne


Standard LSTM




Standard GRU



dLSTM




dRNNCell



adRNNCell – nowe komórki rekurencyjne z mechanizmem dylatacji i uwagi

- adRNNCell łączy dwie komórki dRNNCell, tworząc bardziej efektywną strukturę, zdolną do dynamicznego wstępnego przetwarzania danych
- Dolna komórka generuje wektor uwagi \mathbf{m}_t , którego składowe wyznaczają wagi wejść przekazywanych do górnej komórki.
- Wektor \mathbf{m}_t ma charakter dynamiczny — jest dostosowywany do aktualnych danych wejściowych w chwili t .



$$\begin{aligned}
 \mathbf{f}_t &= \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{V}_f \mathbf{h}_{t-1} + \mathbf{U}_f \mathbf{h}_{t-d} + \mathbf{b}_f) \\
 \mathbf{u}_t &= \sigma(\mathbf{W}_u \mathbf{x}_t + \mathbf{V}_u \mathbf{h}_{t-1} + \mathbf{U}_u \mathbf{h}_{t-d} + \mathbf{b}_u) \\
 \mathbf{o}_t &= \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{V}_o \mathbf{h}_{t-1} + \mathbf{U}_o \mathbf{h}_{t-d} + \mathbf{b}_o) \\
 \tilde{\mathbf{c}}_t &= \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{V}_c \mathbf{h}_{t-1} + \mathbf{U}_c \mathbf{h}_{t-d} + \mathbf{b}_c) \\
 \mathbf{c}_t &= \mathbf{u}_t \otimes (\mathbf{f}_t \otimes \mathbf{c}_{t-1} + (1 - \mathbf{f}_t) \otimes \mathbf{c}_{t-d}) \\
 &\quad + (1 - \mathbf{u}_t) \otimes \tilde{\mathbf{c}}_t \\
 \mathbf{x}_t^2 &= \mathbf{x}_t \otimes \mathbf{m}_t \\
 \mathbf{h}_t^{1'} &= \mathbf{o}_t^1 \otimes \mathbf{c}_t^1 \\
 \mathbf{h}_t^1 &= [h_{t,1}^{1'}, \dots, h_{t,s_h}^{1'}] \\
 \mathbf{m}_t &= [h_{t,s_h+1}^{1'}, \dots, h_{t,s_h+s_m}^{1'}] \\
 \mathbf{h}_t^{2'} &= \mathbf{o}_t^2 \otimes \mathbf{c}_t^2 \\
 \mathbf{h}_t^2 &= [h_{t,1}^{2'}, \dots, h_{t,s_q}^{2'}] \\
 \mathbf{y}_t &= [h_{t,s_q+1}^{2'}, \dots, h_{t,s_q+s_y}^{2'}]
 \end{aligned}$$

Table 1. Forecasting quality metrics.

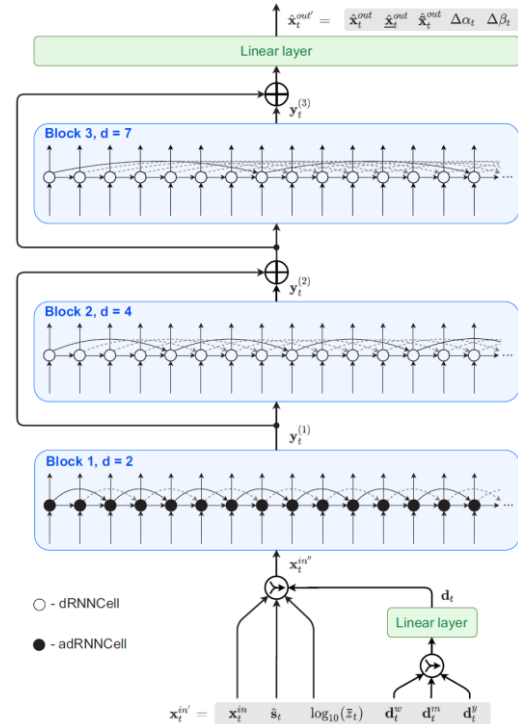
Cell type	MAPE	MdAPE	IqrAPE	RMSE	MPE	StdPE
GRU1	2.31	2.10	2.23	318.69	-0.06	3.86
GRU2	2.26	2.04	2.19	308.92	-0.15	3.78
LSTM1	2.25	2.03	2.18	307.09	-0.19	3.78
LSTM2	2.16	1.94	2.10	293.00	-0.10	3.60
dLSTM	2.19	1.97	2.12	297.58	-0.19	3.66
dRNNCell	2.15	1.93	2.09	292.60	-0.15	3.57
adRNNCell	2.12	1.91	2.07	289.32	-0.14	3.52

LSTM1, GRU1 – komórki bez połączeń opóźnionych

LSTM2, GRU2 - komórki zasilane stanami opóźnionymi $t - 2$, $t - 4$ lub $t - 7$, zależnie od warstwy

Architektura sieci adRNN

- Warstwa liniowa wejściowa redukuje wymiarowość zmiennych kalendarzowych poprzez ich osadzenie w r -wymiarowym wektorze ciągłym \mathbf{d}_t
- Warstwa liniowa wyjściowa generuje:
 - prognozę punktową na 24 h
 - dwa wektory kwantyli, dolny i górny, które definiują przedział predykcji (PI)
 - korekty współczynników wygładzania dla ES, $\Delta\alpha_t, \Delta\beta_t$.
- Sieć RNN wykorzystuje obejścia typu ResNet pomiędzy blokami w celu usprawnienia procesu uczenia.




Aby umożliwić RNN generowanie zarówno prognoz punktowych, jak i kwantyli dla przedziału predykcji, definiujemy następującą funkcję straty:

$$L = \rho(y, \hat{y}_{q^*}) + \gamma (\rho(y, \hat{y}_{q^l}) + \rho(y, \hat{y}_{q^u}))$$

gdzie

$$\rho(y, \hat{y}_q) = (y - \hat{y}_q)(q - \mathbf{1}_{(y < \hat{y}_q)})$$



to *pinball loss*, $q \in (0,1)$ to rząd kwantyla, y to wartość rzeczywista, \hat{y}_q to prognoza q -tego kwantyla y , $q^* = 0.5$ odpowiada medianie, $q^l \in (0, q^*)$ i $q^u \in (q^*, 1)$ odpowiadają dolnej i górnej granicy przedziału predykcji, $\gamma \geq 0$.

Prognozy godzinowego zapotrzebowania na energię elektryczną dla 35 państw europejskich w horyzoncie 24 h.

Okres danych obejmuje lata 2006-2018 (około 60% państw ma kompletne dane).

Okres testowy: 2018.

Prognozowanie STLF realizowane jest w dwóch wariantach:

- z wykorzystaniem ES-adRNN jako modelu indywidualnego,
- z wykorzystaniem zespołu pięciu modeli bazowych ES-adRNN (ES-adRNNe).

Naive – model naiwny: prognozowany profil zapotrzebowania dla dnia i jest taki sam jak dla dnia $i-7$,

ARIMA – model autoregresyjny zintegrowany średniej ruchomej,

ES – model wygładzania wykładniczego,

Prophet – modułowy model regresji addytywnej z nieliniowym trendem i składowymi sezonowymi,

FNM – model rozmytego sąsiedztwa,

GRNN – uogólniona regresyjna sieć neuronowa,

MLP – perceptron wielowarstwowy z jedną warstwą ukrytą i nieliniowością sigmoidalną,

SVM – liniowa maszyna wektorów nośnych,

LSTM – sieć neuronowa typu *long short-term memory*,

ANFIS – adaptacyjny system wnioskowania neuro-rozmytego,

MTGNN – grafowa sieć neuronowa do prognozowania wielowymiarowych szeregów czasowych,

ES-dRNN – hybrydowy model łączący wygładzanie wykładnicze i dylatacyjną sieć rekurencyjną,

ES-dRNNe – zespół pięciu modeli bazowych ES-dRNN.

TABLE I
FORECASTING QUALITY METRICS.

	MAPE	MdAPE	IqrAPE	RMSE	MPE	StdPE
Naive	5.08	4.84	3.32	704.34	-0.26	7.91
ARIMA	3.30	3.01	3.00	475.09	-0.01	5.31
ES	3.11	2.88	2.73	439.26	0.01	5.13
Prophet	4.53	4.32	3.03	619.39	-0.13	6.82
FNM	2.50	2.30	2.29	334.08	-0.11	4.27
GRNN	2.48	2.28	2.27	332.91	-0.11	4.25
MLP	3.05	2.78	2.94	419.01	-0.04	5.07
SVM	2.55	2.29	2.52	357.24	-0.13	4.37
LSTM	2.76	2.57	2.52	381.76	0.02	4.47
ANFIS	3.65	3.17	3.66	507.08	-0.10	6.43
MTGNN	2.99	2.74	2.69	405.18	-0.47	4.85
ES-dRNN	2.33	2.13	2.23	319.04	-0.20	3.90
ES-dRNN _e	2.25	2.05	2.17	309.88	-0.20	3.79
ES-adRNN	2.28	2.08	2.19	315.44	-0.16	3.82
ES-adRNN _e	2.20	2.01	2.13	303.70	-0.13	3.71

(trening i optymalizacja na danych z okresu 2016-17)

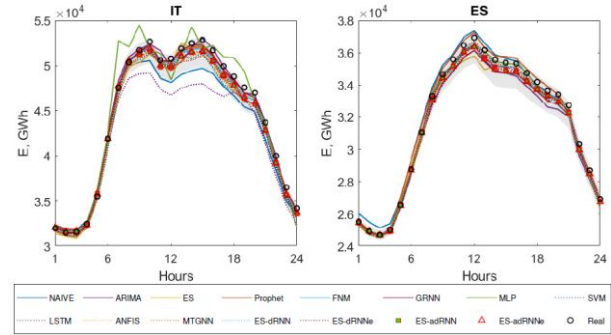

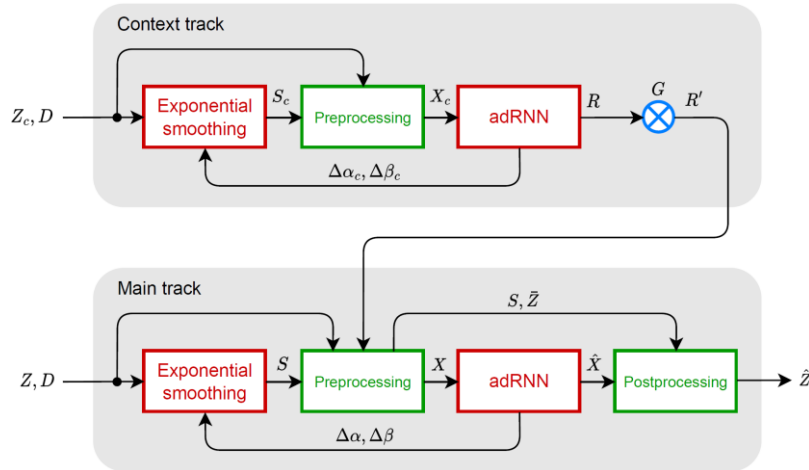


Fig. 6. Examples of the forecasted daily profiles. 90% PIs for ES-adRNNe are shown as gray-shaded areas.

Architektura cES-adRNN



Modulacja odpowiedzi ścieżki kontekstowej

$$\mathbf{r}'_t^{(j)} = \mathbf{r}_t \otimes \mathbf{g}_t^{(j)}$$

Modele hybrydowe ze ścieżką kontekstową

Sieć adRNN





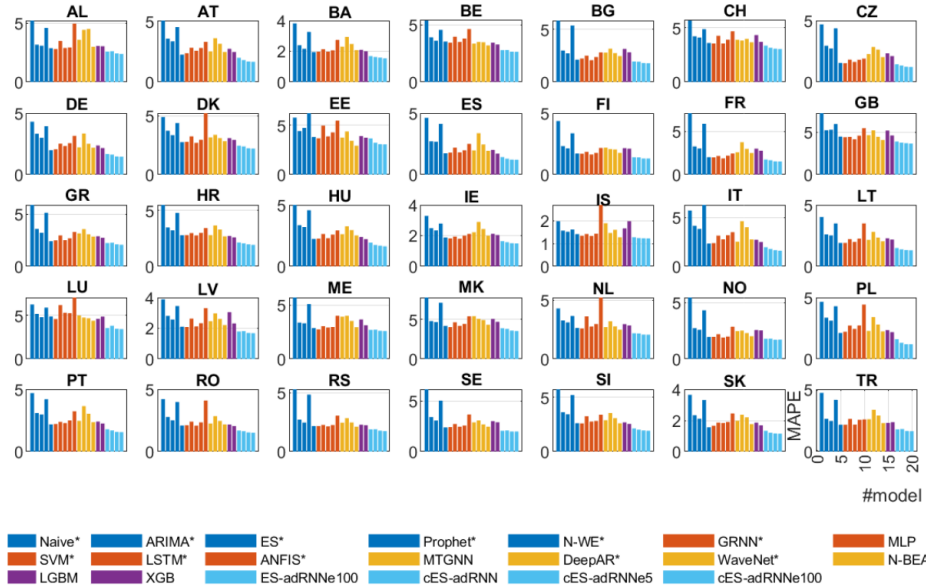
TABLE II
QUALITY METRICS.

	MAPE	MdAPE	IqrAPE	RMSE	MPE	StdPE	GWtest
Naive*	5.08	4.84	3.32	704.34	-0.26	7.91	1.05
ARIMA*	3.30	3.01	3.00	475.09	-0.01	5.31	18.35
ES*	3.11	2.88	2.73	439.26	0.01	5.13	27.37
Prophet*	4.53	4.32	3.03	619.39	-0.13	6.82	6.77
N-WE*	2.49	2.28	2.30	332.49	-0.13	4.26	59.25
GRNN*	2.48	2.28	2.27	332.91	-0.11	4.25	61.80
MLP	2.92	2.68	2.78	395.72	0.09	5.04	33.68
SVM*	2.55	2.29	2.52	357.24	-0.13	4.37	56.69
LSTM*	2.76	2.57	2.52	381.76	0.02	4.47	39.70
ANFIS*	3.65	3.17	3.66	507.08	-0.10	6.43	13.53
MTGNN	2.87	2.62	2.59	372.65	-0.02	4.64	33.68
DeepAR*	3.42	3.25	2.95	487.14	-0.51	5.16	17.59
WaveNet*	3.03	2.84	2.69	417.49	-0.83	4.68	28.42
N-BEATS*	2.56	2.36	2.39	356.83	-0.04	4.29	51.58
LGBM	2.87	2.60	2.52	391.16	-0.05	4.64	36.99
XGB	2.69	2.43	2.42	366.97	0.00	4.20	48.57
ES-adRNNe100	2.14	1.93	2.09	290.89	-0.11	3.60	81.95
cES-adRNN	2.08	1.86	2.04	281.15	-0.25	3.39	84.66
cES-adRNNe5	1.96	1.74	1.93	265.37	-0.25	3.22	93.23
cES-adRNNe100	1.93	1.71	1.91	262.65	-0.25	3.19	95.49

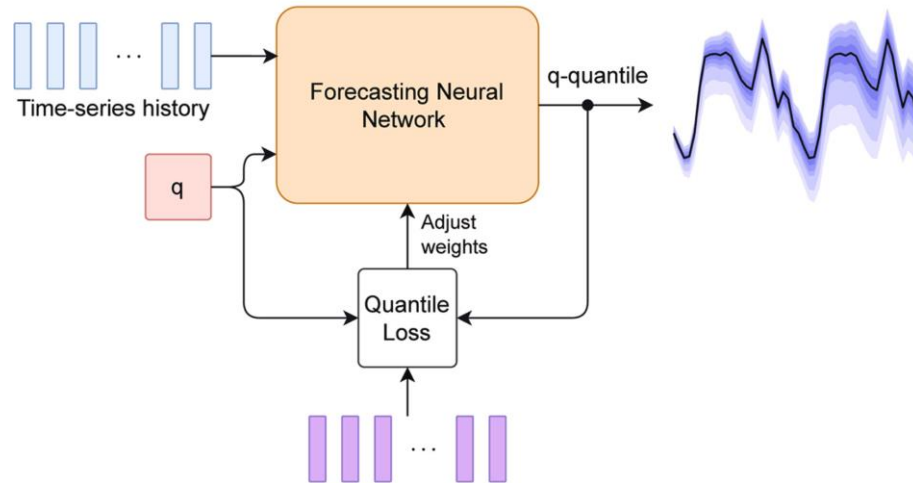


MAPE depending on the ensemble size.

Modele hybrydowe ze ścieżką kontekstową



Sieć prognozująca dowolny kwantyl



Wersja AQ-ESRNN

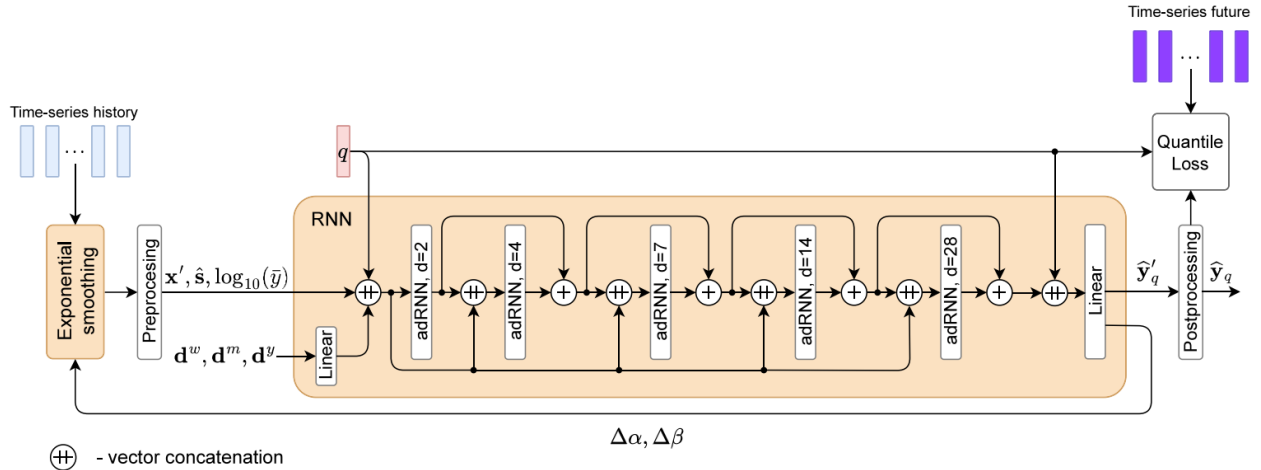



Fig. 2. AQ-ESRNN architecture.


Prognozy probabilistyczne: *Any-quantile NN*

Wersja N-BEATS



(a) AQ-CAT, the target quantile probability is concatenated as one of the elements in the input sequence

(b) AQ-FiLM, the target quantile probability is injected in every N-BEATS block via FiLM modulation layer.



(c) AQ-OUT, the target quantile probability is injected in the last N-BEATS block only.

Wyniki

Table 3

Key performance metrics. Lower score is better. Best result is shown in bold.

	CRPS	N-CRPS	MAPE
Naive	502.62	3.95	5.08
ARIMA	353.49	2.83	3.74
ES	325.80	2.64	3.48
Theta	329.99	2.69	3.56
QR	357.38	2.90	3.92
NGBoost	329.21	2.72	3.75
MLP	415.67	3.28	4.49
DeepAR	378.46	2.97	3.95
WaveNet	293.38	2.52	3.39
Transformer	380.41	2.83	3.72
TFT	325.80	2.92	3.96
AQ-ESRNN	195.94	1.72	2.32
AQ-NBEATS	211.22	1.84	2.47

Wyniki

Naive	0	0	1	1	0	0	0	0	1	0	2	0	0
ARIMA	35	0	1	4	13	6	27	9	2	7	7	0	0
ES	34	30	0	19	26	10	32	23	4	15	11	0	0
Theta	34	27	10	0	27	6	33	23	4	13	7	0	0
QR	34	8	3	4	0	6	27	11	3	6	7	0	0
NGBoost	35	24	21	23	28	0	32	26	13	25	14	0	1
MLP	35	2	1	2	3	0	0	4	1	2	5	0	0
DeepAR	35	13	4	2	16	4	31	0	2	5	6	0	0
WaveNet	34	31	28	30	30	13	33	33	0	30	20	0	0
Transformer	34	20	7	10	23	8	32	24	2	0	8	0	0
TFT	33	25	21	22	26	13	29	27	13	23	0	0	0
AQ-ESRNN	35	35	35	35	35	35	35	35	34	35	35	0	24
AQ-NBEATS	35	35	35	35	35	34	35	35	35	35	35	5	0
	Naive	ARIMA	ES	Theta	QR	NGBoost	MLP	DeepAR	WaveNet	Transformer	TFT	AQ-ESRNN	AQ-NBEATS

Fig. 7. Results of the Diebolt-Mariano test based on the N-CRPS metric ($\alpha = 0.05$). Individual cells count the number of countries the model represented on the y-axis is statistically more accurate than the model represented on the x-axis.

Wyniki

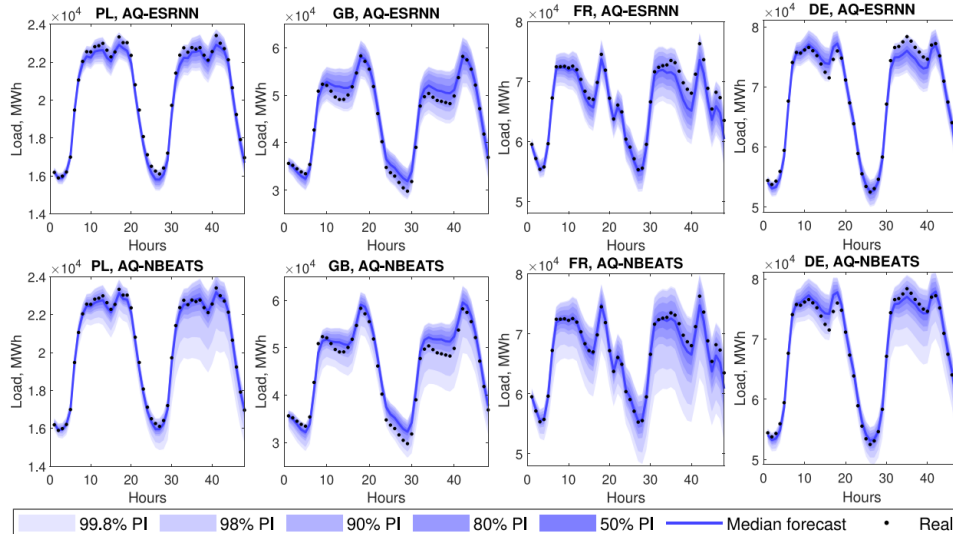


Fig. 10. Examples of quantile forecasts for 30 and 31 January 2018.

Prognozy probabilistyczne: *Any-quantile NN*

Information Fusion 127 (2026) 103637



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

Information Fusion

journal homepage: www.elsevier.com/locate/infus



Full length article

Any-quantile probabilistic forecasting of short-term electricity demand:
Fusing uncertainties from diverse sources

Slawek Smyl^a, Boris N. Oreshkin^b, Paweł Pełka^c, Grzegorz Dudek^c*

^a Walmart, USA

^b Amazon, Canada

^c Department of Electrical Engineering, Czestochowa University of Technology, 42-200 Czestochowa, Al. Armii Krajowej 17, Poland



Slawek Smyl, Walmart
(cES-adRNN)



Boris Oreshkin, Amazon
(N-BEATS)



Paweł Pełka, PCz



Grzegorz Dudek, PCz



W modelach hybrydowych wprowadzono wiele mechanizmów i procedur zwiększających dokładność modelu:

- architektura hybrydowa – ES do dynamicznego preprocessingu w locie (uczenie się reprezentacji szeregów) oraz RNN do modelowania zależności czasowych w szeregach,
- hierarchiczna architektura RNN, która uczy się zależności czasowych o różnej skali w różnych warstwach,
- nowe komórki rekurencyjne z połączeniami opóźnionymi i mechanizmem *attention*, które pomagają w modelowaniu zależności długookresowych i sezonowych oraz selekcji informacji wejściowej,
- dynamiczny model ES – RNN koryguje parametry ES,
- *cross-learning*, który umożliwia modelowi uchwycenie wspólnych cech poszczególnych szeregów i zapobiega nadmiernemu dopasowaniu modelu do indywidualnych szeregów,
- asymetryczna sparametryzowana funkcja straty oparta na kwantylach, która umożliwia generowanie zarówno prognoz punktowych, jak i przedziałów predykcji, a także redukcję obciążenia prognozy,
- ścieżka kontekstowa, która wprowadza dodatkowe informacje „wydobyte” z reprezentatywnych lub skorelowanych szeregów czasowych,
- *any-quantile* – prognozowanie dowolnych kwantyli.

Dziękuję za uwagę



Organizator: Polskie Towarzystwo Elektrotechniki Teoretycznej i Stosowanej PTETiS
Oddział w Częstochowie, Wydział Elektryczny Politechniki Częstochowskiej

Patronat honorowy



JM Rektor
Politechniki
Częstochowskiej



Wydział
Elektryczny

Dziekan Wydziału
Elektrycznego PCz



POLSKA AKADEMIA NAUK
Komisja Energetyki
Oddz. PAN
w Katowicach



Stowarzyszenie
na rzecz
Gospodarki
Energetycznej
Polski



Stowarzyszenie
Elektryków
Polskich



Polskie
Towarzystwo
Przesyłu i Rozdziału
Energii Elektrycznej

Informacje: grzegorz.dudek@pcz.pl