

Rețele neuronale și deep learning

Cursul 13: Deep learning pentru serii de timp din energie și finanțe; modele fundație pentru serii de timp



Prof. dr. Daniel Traian PELE

Academia de Studii Economice din București (ASE), Departamentul de Statistică și Econometrie
Academia Română, Institutul de Prognoză Economică (IPE)
IDA Institute Digital Assets ▪ AI4EFin ▪ MSCA Digital Finance

Obiectivele cursului

- Să formulați o problemă de prognoză pentru ziua următoare fără scurgeri de informație: setul de informații la închiderea licitației, originea glisantă, modelele de referință.
- Să scrieți și să estimați modelul autoregresiv estimat prin Lasso (LEAR), o rețea neuronală profundă (DNN) cu 24 de ieșiri și analiza prin expansiune în baze neuronale (N-BEATS) pe prețurile din România.
- Să explicați cum prognozează modelele fundație pentru serii de timp, Chronos și modelul fundație al Google Research (TimesFM), fără antrenare pe datele noastre și să le testați.
- Să comparați prognozele cu testul Diebold–Mariano și să calibrați prognozele probabilistice prin predicție conformală.
- Să folosiți un model fundație pentru valoarea expusă la risc și să o testați retrospectiv pe S&P 500 și Bitcoin.

Abrevieri (1/2)

AIC	criteriul informațional Akaike
ASE	Academia de Studii Economice din București
CET	ora Europei Centrale
CQR	regresie cuantilă conformală
DE-LU	zona de ofertare Germania–Luxemburg
DeepAR	rețea recurentă autoregresivă profundă (Salinas et al., 2020)
DM	testul Diebold–Mariano
DNN	rețea neuronală profundă (aici: perceptron multistrat cu 24 de ieșiri)
ENTSO-E	Rețeaua europeană a operatorilor de transport și de sistem pentru energie electrică
ES	pierderea așteptată în coada distribuției (expected shortfall)
EUR	euro
GARCH	heteroscedasticitate condiționată autoregresivă generalizată
HS	simulare istorică
HU	Ungaria (zonă de ofertare)
IPE	Institutul de Prognoză Economică, Academia Română
ISE	Institutul Fraunhofer pentru Sisteme de Energie Solară
LEAR	model autoregresiv estimat prin Lasso
LLM	model lingvistic mare
LR	raportul de verosimilitate
LSTM	rețea cu memorie pe termen scurt și lung
MAD	abaterea absolută mediană
MAE	eroarea absolută medie
MAPE	eroarea procentuală absolută medie
MLP	perceptron multistrat

Abrevieri (2/2)

MW	megawatt
MWh	megawatt-oră
N-BEATS	analiza prin expansiune în baze neuronale pentru serii de timp
OPCOM	operatorul pieței de energie electrică și gaze naturale din România
PatchTST	arhitectura transformer pe petice de serie de timp
ReLU	funcția liniară rectificată
RMSE	rădăcina erorii pătratice medii
RO	România (zonă de ofertare)
TimesFM	modelul fundație pentru serii de timp al Google Research
VaR	valoarea expusă la risc (Value-at-Risk)

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

Două decizii de afaceri bazate pe prognoze pentru ziua următoare

- **Energie: ofertarea pe piața pentru ziua următoare**
  - Un furnizor, un producător hidro sau operatorul unei baterii trimite oferte pentru cele 24 de ore de mîine înainte de ora 12:00, ora Europei Centrale (CET), de azi
  - Prețul fiecărei ore este stabilit de o singură licitație, cuplată la nivel european; în România o organizează operatorul pieței de energie electrică și gaze naturale (OPCOM)
  - O eroare de 1 EUR/MWh pe 100 MW timp de 24 de ore costă 2.400 de euro pe zi
- **Finanțe: valoarea expusă la risc (VaR) a unui portofoliu**
  - O bancă raportează zilnic pierderea depășită cu probabilitatea de 1 %; regulile Basel numără depășirile
  - Este o prognoză de cuantilă, nu una punctuală
- **Întrebarea acestui curs**
  - Sînt rețelele antrenate pe datele noastre sau modelele fundație preantrenate pe milioane de alte serii mai bune decît reperele simple?

(Weron, 2014; Lago et al., 2021)

Datele: prețurile și consumul de energie din România, S&P 500 și Bitcoin

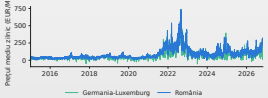
Serie	Frecvență	Sursă	Folosită pentru
Prețurile pentru ziua următoare: România (RO), Germania–Luxemburg (DE-LU), Ungaria (HU)	orară	energy-charts.info, Institutul Fraunhofer pentru Sisteme de Energie Solară (ISE), din datele burselor și ale Rețelei europene a operatorilor de transport și de sistem pentru energie electrică (ENTSO-E)	prognoza prețului
Consumul României	orară	energy-charts.info, ENTSO-E	prognoza consumului
S&P 500, Bitcoin (BTC/USD)	zilnică	Yahoo Finance	valoarea expusă la risc

- Prețuri din 1 ianuarie 2015 pînă la 31 octombrie 2026: 103 595 de prețuri orare; anul de test este 1 noiembrie 2025 – 31 octombrie 2026: 364 de zile complete.
- Orele lipsă rămîn lipsă; cele două zile pe an cu schimbarea orei sînt păstrate doar dacă există toate cele 24 de ore.

Media zilnică a prețurilor pentru ziua următoare în România

- **Pe scurt:** un model antrenat înainte de 2021 nu a văzut niciodată prețuri ca în 2022; unul antrenat pe 2022 supraestimează prețurile de azi.

$$\bar{P}_d = \frac{1}{24} \sum_{h=0}^{23} P_{d,h}$$



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 ianuarie 2015 - 31 octombrie 2026, medii zilnice ale prețurilor orare.

- Media 2019: 50,41 EUR/MWh
  - Media 2022: 265,31 EUR/MWh
  - Ziua maximă: 738,28, pe 30 august 2022
  - Corelația mediilor zilnice RO–DE-LU: 0,94.

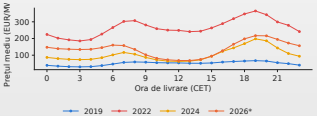
- **În practică:** alegeți fereastra de antrenare în mod deliberat: aici, trei ani, ca la Lago et al. (2021).

NN_L13_price_history

Producția solară a transformat vîrful de la prînz într-un minim

- **Pe scurt:** forma pe ore este cea mai puternică regularitate pe care o poate învăța un model și s-a schimbat în doar șase ani.

$$\bar{P}^{(y)}_{\cdot,h} = \frac{1}{|D_y|} \sum_{d \in D_y} P_{d,h}$$



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 2019, 2022, 2024 și 2026 (*ianuarie-octombrie), România.

- 2026 (ianuarie–octombrie): ora cea mai ieftină este 13, cu 67,90 EUR/MWh, iar cea mai scumpă este 19, cu 217,05 EUR/MWh.

- **În practică:** prognoza trebuie să acopere 24 de ore diferite, nu un singur număr pe zi: de aici cele 24 de ieșiri ale modelelor.

NN_L13_hourly_profile

Setul de informații la închiderea licitației: ce poate folosi modelul

- **Pe scurt:** o prognoză pentru ziua d poate folosi doar ce se știe înainte de ora 12:00 CET din ziua $d-1$.

$$\hat{\mathbf{y}}_d = f_{\boldsymbol{\theta}}(\mathbf{x}_d), \quad \mathbf{x}_d \in \mathcal{I}_{d-1}$$
$$\mathbf{x}_d = (\mathbf{y}_{d-1}, \mathbf{y}_{d-2}, \mathbf{y}_{d-3}, \mathbf{y}_{d-7}, \mathbf{y}^{\mathrm{DE}}_{d-1}, \ell_{d-2}, \mathbf{c}_d)$$

- **unde**
  - $\mathbf{y}_d \in \mathbb{R}^{24}$ = prețurile din România în ziua d
  - $\mathbf{y}^{\mathrm{DE}}$ = prețurile DE-LU
  - ℓ = consumul României (complet cu două zile în urmă)
  - $\mathbf{c}_d$ = variabilele pentru ziua săptămânii
  - $\mathcal{I}_{d-1}$ = informația de la închiderea licitației.

- **151 de variabile de intrare** și 3 819 eșantioane zilnice din 2016.
- **Origine glisantă**: reestimare pe ultimele 1 092 de zile, prognoză pentru ziua următoare, avans cu o zi.
- **Testare o singură dată**: 364 de zile nefolosite nici la estimare, nici la ajustare.

- **În practică:** consumul zilei $d-1$ nu este complet la prînz
  - Folosirea lui ar introduce viitorul în prognoză.

Exerciții practic: notebook §1

Măsurile erorii și modelul de referință

- **Pe scurt:** erorile se raportează în EUR/MWh și relativ la prognoza naivă, niciodată ca procent dintr-un preț care poate fi zero.

$$\mathrm{MAE} = \frac{1}{24|\mathcal{T}|} \sum_{d \in \mathcal{T}} \sum_{h} |y_{d,h} - \hat{y}_{d,h}|, \quad \mathrm{rMAE} = \frac{\mathrm{MAE}}{\mathrm{MAE}^{\mathrm{naive}}}$$

$$\hat{y}^{\mathrm{naive}}_{d,h} = \begin{cases} y_{d-7,h}, & \text{lun., sîm., dum.} \\ y_{d-1,h}, & \text{mar.–vin.} \end{cases}$$

- **unde**
  - $\mathcal{T}$ = zilele de test
  - $\mathrm{rMAE} < 1$ = mai bun decît modelul naiv
  - Rădăcina erorii pătratice medii (RMSE) ponderează mai mult vîrfurile.

- **Anul de test**: media 134,59 EUR/MWh, abaterea standard 77,19, între −97,55 și 954,59
  - 195 de ore cu preț negativ.
- **Modelul naiv**: eroarea absolută medie (MAE) 27,74 EUR/MWh.

- **În practică:** un model cu rMAE peste 1 nu trebuie folosit, oricît de profund ar fi.

Exercițiu practic: notebook §1

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

Transformarea care stabilizează varianța: vîrfuri de preț și prețuri negative

- **Pe scurt:** sinusul hiperbolic invers se comportă ca un logaritm pentru prețuri mari și ca identitatea în jurul lui zero, deci acceptă prețuri negative.

$$z = \operatorname{asinh}\left(\frac{y - \tilde{m}}{\hat{\sigma}}\right), \quad \hat{\sigma} = \frac{\mathrm{MAD}}{0.6745}, \quad y = \tilde{m} + \hat{\sigma}\sinh(\hat{z})$$

- **unde**
  - $\tilde{m}$ = mediana ferestrei de antrenare
  - Abaterea absolută mediană (MAD) scalată la o abatere standard
  - $\hat{z}$ = prognoza pe scara transformată.

- **Estimată doar pe fereastră**: nicio informație din test nu intră în $\tilde{m}$ și $\hat{\sigma}$.
- **Aceeași transformare pentru LEAR și DNN**, astfel încît diferențele vin din model, nu din scară.

- **În practică:** transformați înainte de estimare, inversați după prognoză, evaluați în EUR/MWh.

(Uniejewski, Weron & Ziel, 2018)

Exercițiu practic: notebook §2

LEAR: 24 de regresii Lasso, cîte una pentru fiecare oră

- **Pe scurt:** un model liniar cu multe decalaje, în care Lasso păstrează doar decalajele care contează pentru fiecare oră.

$$\hat{\beta}_h = \arg\min_{\beta} \sum_{d \in W} \left(z_{d,h} - \mathbf{x}_d^\top \beta \right)^2 + \lambda_h \|\beta\|_1$$

- **unde**
  - W = ultimele 1 092 de zile
  - λ_h ales prin criteriul informațional Akaike (AIC) pe traiectoria Lasso
  - Reestimare zilnică: 364 × 24 de estimări.

- **Modelul autoregresiv estimat prin Lasso (LEAR)**: MAE 22,79 EUR/MWh, rMAE 0,822.
- **De ce este greu de depășit**: se estimează în cîteva secunde, este interpretabil și se adaptează zilnic.

- **În practică:** raportați întotdeauna LEAR lîngă orice rețea: este reperul deschis al domeniului.

(Lago et al., 2021)

Exercițiu practic: notebook §2

Rețeaua DNN: o singură rețea, 24 de ieșiri, aceleași intrări

- **Pe scurt:** un perceptron multistrat (MLP) prognozează întreaga zi deodată, iar orele împart ce învață.

$$\hat{\mathbf{z}}_d = \mathbf{W}_3\ \mathrm{ReLU}\left(\mathbf{W}_2\ \mathrm{ReLU}(\mathbf{W}_1\mathbf{x}_d + \mathbf{b}_1) + \mathbf{b}_2\right) + \mathbf{b}_3$$

$$\mathcal{L} = \frac{1}{24|W'|}\sum_{d\in W'} \|\mathbf{z}_d - \hat{\mathbf{z}}_d\|_1, \quad z_{d,h} = \operatorname{asinh}\frac{y_{d,h} - m_d}{s_d}$$

- **unde**
  - m_d = mediana prețurilor din ziua $d-1$
  - s_d = MAD a prețurilor decalate + 1
  - Funcția liniară rectificată (ReLU)
  - W' = primele 80 % din fereastră.

- **Rețeaua neuronală profundă (DNN)**: MAE 23,06 EUR/MWh, media a 4 rulări (individual: 23,57–24,03).
- **Dimensiune**: 256 și 128 de neuroni, 74 904 parametri, dropout 0,1, Adam, oprire timpurie pe ultimele 20 %.
- **Scalarea pe fiecare zi** păstrează rețeaua utilizabilă cînd nivelul prețului sare.

- **În practică:** faceți media mai multor rulări
  - O singură rulare este o extragere dintr-un estimator aleator.

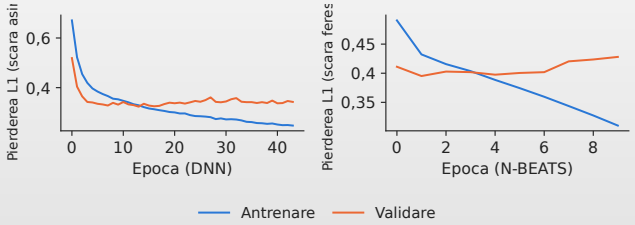
(Lago et al., 2021)

Exerciții practic: notebook §3

Oprirea timpurie alege epoca pe date pe care rețeaua nu s-a antrenat

- **Pe scurt:** pierderea pe antrenare continuă să scadă; pierderea pe validare arată cînd trebuie oprită antrenarea.

$$e^* = \arg\min_e \mathcal{L}_{\text{val}}(\theta_e)$$



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: ferestre de antrenare dinainte de 1 noiembrie 2025, România.

- DNN: epoca optimă 14 din 44
  - N-BEATS: epoca optimă 2 din 10 (regula răbdării).

NN_L13_training_curves

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

O rețea recurentă probabilistă pentru prognoză

- **Pe scurt:** starea recurentă rezumă trecutul; rețeaua produce parametrii distribuției de mîine.

$$\mathbf{h}_t = \mathrm{LSTM}(\mathbf{h}_{t-1}, y_{t-1}, \mathbf{c}_t), \quad y_t \mid \mathbf{h}_t \sim \mathcal{N}\Big(\mu(\mathbf{h}_t), \sigma^2(\mathbf{h}_t)\Big)$$

$$\mathcal{L} = -\sum_t \log p\Big(y_t \mid \mu(\mathbf{h}_t), \sigma(\mathbf{h}_t)\Big)$$

- **unde**
  - Rețea cu memorie pe termen scurt și lung (LSTM, cursul 5)
  - $\mathbf{c}_t$ = covariabile
  - Antrenată simultan pe multe serii înrudite
  - Prognozele pe mai mulți pași se obțin eșantionînd y_t și reintroducîndu-l în rețea.

- **Rețeaua recurentă autoregresivă profundă (DeepAR)**: un singur model global pentru multe serii.
- **Ideea ei continuă** în modelele fundație de mai jos: antrenare globală, prognoză probabilistică.

- **În practică:** este utilă cînd aveți mii de serii înrudite (magazine, contoare, active), nu una singură.

(Salinas et al., 2020)

N-BEATS: blocuri suprapuse care explică intrarea și prognozează restul

- **Pe scurt:** fiecare bloc elimină din intrare ce poate explica (reconstrucția) și adaugă contribuția sa la prognoză.

$$\mathbf{h}_\ell = \mathrm{FC}_\ell(\mathbf{r}_{\ell-1}), \quad \hat{\mathbf{r}}_\ell = \mathbf{V}_\ell^b \mathbf{h}_\ell, \quad \hat{\mathbf{y}}_\ell = \mathbf{V}_\ell^f \mathbf{h}_\ell$$

$$\mathbf{r}_\ell = \mathbf{r}_{\ell-1} - \hat{\mathbf{r}}_\ell, \qquad \hat{\mathbf{y}} = \sum_{\ell=1}^{L} \hat{\mathbf{y}}_\ell$$

- **unde**
  - $\mathbf{r}_0$ = ultimele 168 ore, standardizate pe fereastră
  - FC_ℓ = 4 straturi de lățime 256
  - $L = 6$ blocuri
  - 1 739 904 parametri
  - ieșire de 24 de ore.

- **Analiza prin expansiune în baze neuronale (N-BEATS)**: doar prețuri, antrenată o singură dată înainte de anul de test, pe toate originile orare.
- **MAE pe test**: 23,23 EUR/MWh (3 rulări: între 23,69 și 24,12).

- **În practică:** o rețea univariată nu vede prețurile din Germania sau consumul: comparați-o cu LEAR, care le folosește.

(Oreshkin et al., 2020)

Exercițiu practic: notebook §3

Arhitecturi transformer pentru serii de timp: peticele ca tokeni

- **Pe scurt:** seria se taie în petice scurte, fiecare petic este reprezentat ca un cuvînt, iar mecanismul de atenție le compară.

$$\mathbf{p}_j = (y_{(j-1)P+1}, \ldots, y_{jP}), \quad \mathbf{e}_j = \mathbf{W}_e \mathbf{p}_j + \mathbf{q}_j$$

$$\mathrm{Attn}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \mathrm{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}\right)\mathbf{V}$$

- **unde**
  - P = lungimea peticului (de exemplu 16 sau 32 de ore)
  - $\mathbf{q}_j$ = codificarea poziției
  - $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ = proiecții ale lui $\mathbf{e}_j$ (cursul 7).

- **Arhitectura transformer pe petice (PatchTST)**: 2.048 de ore devin 128 de tokeni de cîte 16: costul atenției scade de 256 de ori.
- **Modelele fundație** de mai jos folosesc exact acest design, preantrenat pe colecții uriașe de serii.

- **În practică:** peticele fac accesibile contextele lungi (săptămîni de date orare).

(Nie et al., 2023)

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

Un model fundație prognozează o serie pe care nu a văzut-o niciodată

- **Pe scurt:** o singură rețea este preantrenată pe multe serii; la utilizare doar citește contextul nostru, fără niciun pas de gradient.

$$\hat{q}^{\tau}_{T+k} = g_{\theta^*}\left(y_{T-C+1:T}\right)_{k,\tau}$$

$$\theta^* = \arg\min_{\theta} \sum_{s\in\mathcal{S}} \sum_{t,\tau} \rho_\tau\left(y^{(s)}_t - \hat{q}^{\tau,(s)}_t\right)$$

- **unde**
  - $\mathcal{S}$ = corpusul de preantrenare (serii publice și sintetice)
  - C = lungimea contextului (aici 2 048 de ore)
  - ρ_τ = pierderea cuantilă (pinball)
  - $k = 1, \ldots, 24$ = orizontul
  - θ^* rămîne fix.

- **Trei modele testate, fără reantrenare (zero-shot)**
  - Chronos-2 (Amazon, 2025): covariabile și mai multe serii împreună
  - Chronos-Bolt base (Amazon): prognoze directe de cuantile
  - Modelul fundație pentru serii de timp al Google Research (TimesFM) 2.5: numai decodor

- **În practică:** zero-shot înseamnă fără cost de antrenare și fără flux de date, dar și fără adaptare la piața noastră.

(Ansari et al., 2024, 2025; Das et al., 2024)

Exercițiu practic: notebook §4

Chronos: tokenizarea seriilor de timp

- **Pe scurt:** seria se scalează, valorile se împart în intervale, iar un model de limbaj prezice intervalul următor.

$$\tilde{y}_t = \frac{y_t}{s}, \quad s = \frac{1}{C}\sum_t |y_t|, \qquad v_t = \mathrm{bin}(\tilde{y}_t) \in \{1, \ldots, B\}$$

$$\mathcal{L} = -\sum_t \log p_\theta(v_{t+1} \mid v_{1:t})$$

- **Scalarea face seriile comparabile**: un preț și un volum de vînzări devin intrări de același tip.
- **Pierderea cuantilă** dă direct prognoze probabilistice.

- **unde**
  - s = scara absolută medie a contextului
  - $B = 4.096$ de intervale
  - Modelul este de tip T5
  - Chronos-Bolt și Chronos-2 folosesc petice și ieșiri de cuantile.

- **În practică:** modelul cunoaște forme (sezonalitate, revenire la medie), nu piața românească.

(Ansari et al., 2024)

Precizia în anul de test: toate cele nouă prognoze, pe aceleași zile

Model	MAE	RMSE	rMAE
Chronos-2 cu covariabile	20,41	33,88	0,736
Chronos-2	20,72	34,23	0,747
ansamblul	20,77	34,27	0,749
Chronos-Bolt	21,67	34,51	0,781
TimesFM	22,37	36,08	0,806
LEAR	22,79	36,27	0,822
DNN	23,06	38,42	0,831
N-BEATS	23,23	36,64	0,837
modelul naiv	27,74	44,57	1,000

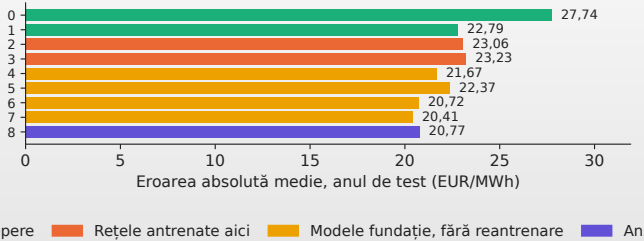
(calcul propriu, EUR/MWh)

- **Cea mai mică MAE**: Chronos-2 cu covariabile, 20,41 EUR/MWh.
- **Cel mai bun model fundație**: Chronos-2 cu covariabile, 20,41, mai bun decît LEAR (22,79), fără nicio antrenare pe datele noastre.
- **Toate modelele** sînt mai bune decît cel naiv: rMAE sub 1.
- Verde = eroare mai mică
  - Semnificația, pe slide-urile următoare.

Exercițiu practic: notebook §4

Rețele antrenate față de modele fundație fără reantrenare

- **Pe scurt:** aceleași 8 736 de ore, același set de informații, nouă strategii de prognoză.



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile x 24 de ore, România.

- Ansamblul = media simplă a LEAR, DNN și Chronos-2: MAE 20,77 EUR/MWh.

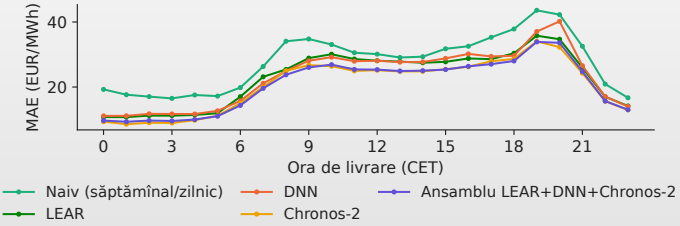
- **În practică:** începeți cu reperul și cu un model fundație: amîndouă costă minute, nu săptămîni.

NN_L13_mae_models

Erorile sînt cele mai mari seara și în orele cu producție solară

- **Pe scurt:** media ascunde orele în care toate modelele greșesc împreună.

$$\mathrm{MAE}_h = \frac{1}{|\mathcal{T}|} \sum_{d \in \mathcal{T}} |y_{d,h} - \hat{y}_{d,h}|$$



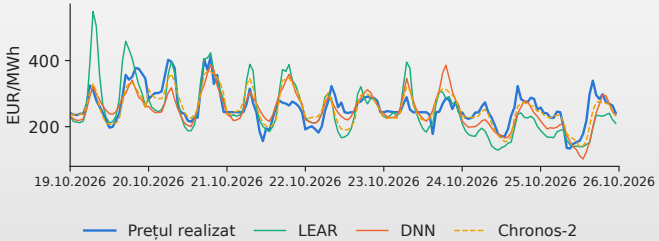
Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile x 24 de ore, România.

- LEAR: ora cea mai grea 19 (35,78), cea mai ușoară 1 (10,75)
  - Chronos-2: ora cea mai grea 19 (34,05).

NN_L13_mae_by_hour

Prognozele pentru o săptămînă din anul de test

- **Pe scurt:** toate cele trei modele urmăresc forma zilnică; niciunul nu anticipează complet cele mai mari vîrfuri de seară.



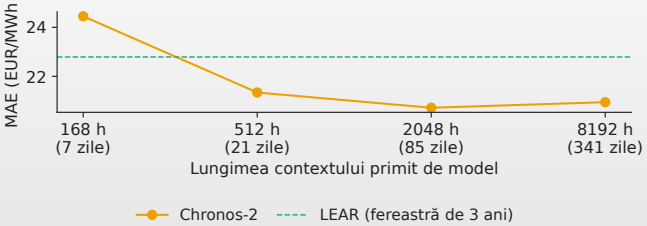
Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 19 octombrie 2026 - 25 octombrie 2026, orar, România.

- Săptămîna 19 octombrie 2026 – 25 octombrie 2026: MAE LEAR 43,34, DNN 32,33, Chronos-2 25,41 EUR/MWh.

NN_L13_forecast_week

Efectul lungimii contextului asupra modelului fundație

- **Pe scurt:** modelul vede doar contextul: o săptămînă arată forma zilnică, trei luni arată și nivelul.



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile x 24 de ore, România.

- MAE Chronos-2: 168 h 24,45, 512 h 21,34, 2.048 h 20,72, 8.192 h 20,95 EUR/MWh.

- **În practică:** lungimea contextului este principalul parametru de ajustare al unui model zero-shot: alegeți-o pe date din trecut.

NN_L13_context_length

Covariabile într-un model fundație: prețurile din Germania și consumul României

- **Pe scurt:** Chronos-2 citește mai multe serii aliniate și lasă mecanismul de atenție să transfere informație între ele.

$$\hat{\mathbf{q}}_{T+1:T+24} = g_{\theta^*}\left(y_{1:T},\ x^{\mathrm{DE}}_{1:T},\ x^{\mathrm{HU}}_{1:T},\ \ell_{1:T}\right)$$

- **unde**
  - Covariabile cunoscute doar în trecut: prețurile DE-LU și HU și consumul României pînă la originea prognozei (valorile lor viitoare nu se cunosc la închiderea licitației).

- **Fără covariabile**: MAE 20,72
  - **cu covariabile**: 20,41 EUR/MWh.
- **Covariabilele au ajutat** aici
  - Testați, nu presupuneți.

- **În practică:** o covariabilă cunoscută dinainte (prognoza meteo sau a consumului) valorează mai mult decît una cunoscută doar în trecut.

(Ansari et al., 2025)

Exercițiu practic: notebook §5

Testul Diebold–Mariano pe pierderile zilnice

- **Pe scurt:** o eroare medie mai mică poate fi noroc; testăm dacă diferența zilnică a pierderilor are media zero.

$$\Delta_d = \|\mathbf{e}_d^A\|_1 - \|\mathbf{e}_d^B\|_1, \qquad \mathrm{DM} = \frac{\bar{\Delta}}{\hat{\sigma}_\Delta / \sqrt{|\mathcal{T}|}} \overset{a}{\sim} \mathcal{N}(0,1)$$

- **unde**
  - $\mathbf{e}_d^A \in \mathbb{R}^{24}$ = erorile modelului A în ziua d
  - O statistică pentru fiecare pereche (varianta multivariată)
  - H_1 unilaterală: B este mai precis decît A
  - $|\mathcal{T}| = 360$ de zile.

- **Diebold–Mariano (DM)**: LEAR față de DNN, $p = 0{,}761$
  - LEAR față de Chronos-2, $p = <0{,}001$.
- **Pe zile, nu pe ore**: orele aceleiași zile folosesc aceeași informație, deci nu sînt independente.

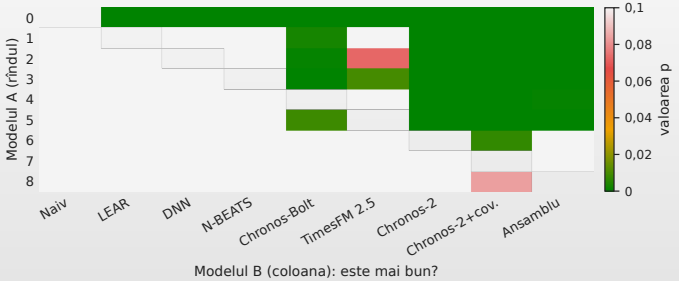
- **În practică:** afirmați că un model este mai bun doar pe baza unui test pe perioada de test.

(Diebold & Mariano, 1995; Ziel & Weron, 2018)

Exercițiu practic: notebook §6

Testele Diebold–Mariano pe perechi de modele

- **Pe scurt:** celulele verzi: modelul din coloană este semnificativ mai precis decît cel din rînd.



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile x 24 de ore, România.

- Ansamblul față de LEAR: $p = <0{,}001$
  - Ansamblul față de Chronos-2: $p = 0{,}565$.

NN_L13_dm_pvalues

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

Prognozele de cuantile se evaluează cu pierderea pinball

- **Pe scurt:** o prognoză de cuantilă este bună cînd sub ea cade proporția corectă de valori, iar banda este îngustă.

$$\rho_\tau(u) = u\left(\tau - \mathbb{1}\{u < 0\}\right), \quad u = y - \hat{q}^\tau$$

$$\mathrm{PL} = \frac{1}{9} \sum_{\tau \in \{0.1,\ldots,0.9\}} \frac{1}{24|\mathcal{T}|} \sum_{d,h} \rho_\tau\left(y_{d,h} - \hat{q}^\tau_{d,h}\right)$$

- **unde**
  - τ = nivelul cuantilei
  - Media pe cele nouă decile aproximează scorul probabilistic continuu (continuous ranked probability score).

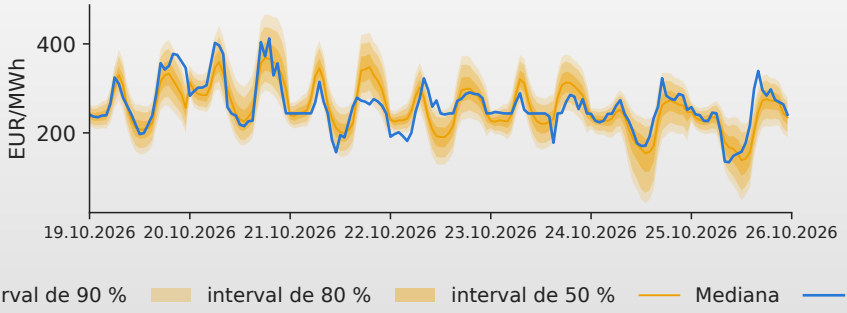
- **Pierderea pinball medie, anul de test** (EUR/MWh)
  - Chronos-2 8,25; cu covariabile 8,11
  - Chronos-Bolt 8,62; TimesFM 8,97
  - LEAR + erorile empirice din ultimele 60 de zile 9,12

- **În practică:** o baterie sau un departament de risc are nevoie de cuantile
  - Evaluați-le cu pinball, nu cu MAE.

Exercițiu practic: notebook §7

O săptămînă de cuantile Chronos-2: banda se lărgește acolo unde prețurile sar

⊡ **Pe scurt:** modelul este mai puțin sigur în orele de seară, exact acolo unde erorile sînt cele mai mari.



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 19 octombrie 2026 - 25 octombrie 2026, orar, România.

NN_L13_chronos_fan

Corecția conformală a intervalelor de prognoză

- **Pe scurt:** măsurăm cît de departe de banda brută au căzut valorile în trecutul recent și lărgim (sau îngustăm) banda cu acea valoare.

$$s_i = \max\left(\hat{q}_i^{\alpha/2} - y_i,\ y_i - \hat{q}_i^{1-\alpha/2}\right), \qquad \hat{Q} = s_{(\lceil (n+1)(1-\alpha) \rceil)}$$

$$\hat{C}_{d,h} = \left[\hat{q}_{d,h}^{\alpha/2} - \hat{Q},\ \hat{q}_{d,h}^{1-\alpha/2} + \hat{Q}\right], \qquad \Pr\left(y \in \hat{C}\right) \geq 1 - \alpha$$

- **Regresia cuantilă conformală (CQR)** aplicată lui Chronos-2, banda de 80 %: acoperire brută 76,5 %, corectată 79,3 %.
- **Lățimea**: 60,03 → 63,89 EUR/MWh.

- **unde**
  - s_i = scorurile de conformitate pe ultimele 60 de zile ($n = 24 \times$ zile)
  - $s_{(k)}$ = a k-a cea mai mică valoare
  - Garanția este exactă pentru date interschimbabile și doar aproximativă pentru serii de timp.

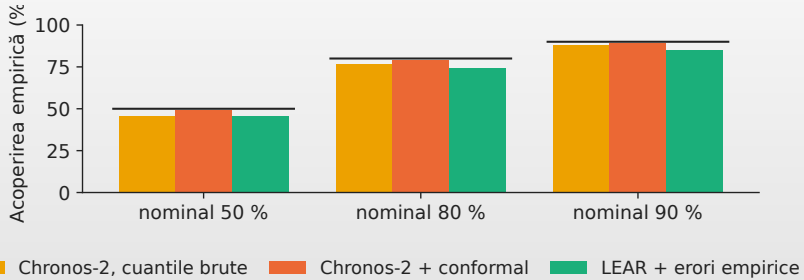
- **În practică:** un model fundație plus calibrarea conformală formează o prognoză probabilistică ieftină și onestă.

(Romano, Patterson & Candès, 2019)

Exercițiu practic: notebook §7

Calibrarea conformală aduce acoperirea spre nivelul nominal

- **Pe scurt:** liniile negre: nivelul nominal; barele: ponderea orelor de test din interiorul benzii.



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile x 24 de ore, România.

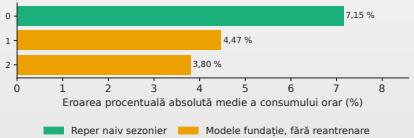
- Banda de 90 %: brut 88,3 %, conformal 89,4 %, LEAR + erori empirice 85,0 %
  - TimesFM 80 %: brut 79,6 %, conformal 79,7 %.

NN_L13_coverage

Prognozele de consum ale modelelor fundație: erori de cîteva procente

- **Pe scurt:** consumul este neted și sezonier, exact formele pe care un model preantrenat le cunoaște cel mai bine.

$$\mathrm{MAPE} = \frac{100}{24|\mathcal{T}|} \sum_{d,h} \left| \frac{\ell_{d,h} - \hat{\ell}_{d,h}}{\ell_{d,h}} \right|$$



Sursa: energy-charts.info (Fraunhofer ISE), din datele burselor și ale ENTSO-E. Date: 1 noiembrie 2025 - 31 octombrie 2026, 360 de zile, consumul României.

- Eroarea procentuală absolută medie (MAPE): săptămîna trecută 7,15 %, TimesFM 4,47 %, Chronos-2 3,80 % (MAE 214,4 MW, consum mediu 5 932 MW).

- **În practică:** erorile procentuale sînt potrivite pentru consum, care nu este niciodată aproape de zero.

NN_L13_load_mape

Cuprins

- Problema de prognoză și datele
- Un reper liniar puternic și o rețea profundă
- Arhitecturi profunde de prognoză
- Modele fundație pentru serii de timp
- Prognoze probabilistice și calibrare conformală
- Modele fundație pentru riscul financiar

Valoarea expusă la risc este o cuantilă condiționată, testată prin numărarea depășirilor

⊡ **Pe scurt:** o VaR de 1 % trebuie depășită în aproximativ 1 % din zile, iar depășirile nu trebuie să vină grupat.

$$\Pr\left(r_{t+1} < \mathrm{VaR}^{\alpha}_{t+1} \mid \mathcal{F}_t\right) = \alpha, \qquad I_{t+1} = \mathbb{1}\{r_{t+1} < \mathrm{VaR}^{\alpha}_{t+1}\}$$

$$\mathrm{LR}_{uc} = -2 \ln \frac{(1-\alpha)^{n_0}\alpha^{n_1}}{(1-\hat{\pi})^{n_0}\hat{\pi}^{n_1}} \sim \chi^2_1$$

⊡ **unde**

- r_t = randamentul logaritmic zilnic (%)
- n_1 = depășirile, n_0 = celelalte zile, $\hat{\pi} = n_1/(n_0 + n_1)$
- Testul raportului de verosimilitate (LR) al lui Kupiec
- Christoffersen adaugă un test de independență a lui I_t.

⊡ **Trei metode**

- Simularea istorică (HS): cuantila empirică a ultimelor 250 de zile
- Heteroscedasticitate condiționată autoregresivă generalizată (GARCH): GARCH(1,1) cu erori Student-t, reestimat la fiecare 21 de zile
- Cuantilele Chronos-2 din ultimele 1.024 de randamente, fără reantrenare

⊡ **În practică:** semaforul Basel depinde de numărul de depășiri ale VaR de 1 % în 250 de zile.

(Kupiec, 1995; Christoffersen, 1998)

Exercițiu practic: notebook §9

O deplasare conformală unilaterală transformă cuantila brută într-o VaR calibrată

- **Pe scurt:** dacă cuantila modelului a fost depășită prea des în ultimul an, o coborîm exact cu valoarea care ar fi corectat-o.

$$s_i = \hat{q}_i^{\alpha} - r_i, \qquad c_t = s_{(\lceil (n+1)(1-\alpha) \rceil)} \text{ pe ultimele } n = 250$$

$$\widehat{\mathrm{VaR}}_{t+1}^{\alpha} = \hat{q}_{t+1}^{\alpha} - c_t$$

- **S&P 500, nivelul de 1 %**: Chronos-2 brut 22 depășiri, conformal 16, așteptate 17,2.
- **Aceeași idee** ca la benzile din energie, aplicată unei singure cozi.

- **unde**
  - $\hat{q}^{\alpha}$ = cuantila brută Chronos-2
  - $c_t > 0$ mărește VaR, $c_t < 0$ o micșorează
  - Deplasarea folosește doar prognoze și randamente din trecut.

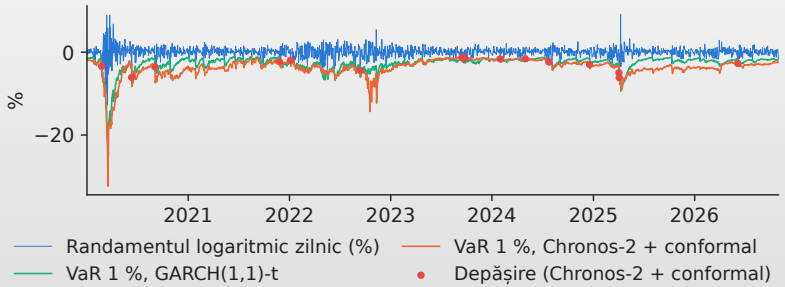
- **În practică:** recalibrarea este o schimbare de model: documentați-o și testați-o pe date noi.

(Romano et al., 2019)

Exercițiu practic: notebook §9

S&P 500: VaR calibrată a modelului fundație urmărește regimurile de volatilitate

- **Pe scurt:** ambele linii se lărgesc în martie 2020 și în aprilie 2025; punctele roșii sînt zilele în care VaR conformală Chronos-2 a fost depășită.



Sursa: Yahoo Finance, cotații zilnice. Date: 2 ianuarie 2020 - 30 octombrie 2026, zile de tranzacționare, S&P 500.

NN_L13_var_sp500

Testarea retrospectivă, ianuarie 2020 – octombrie 2026: S&P 500 și Bitcoin

Activ	Model	Dep. 1 %	p_{uc}	p_{ind}	Dep. 5 %	p_{uc}	Pierdere tick 5 %
S&P 500	HS (250 de zile)	31	0,003	0,002	89	0,729	0,1582
	GARCH(1,1)-t	32	0,001	0,607	132	0,000	0,1347
	Chronos-2, brut	22	0,262	0,285	122	0,000	0,1368
	Chronos-2 + conformal	16	0,774	0,138	93	0,434	0,1383
Bitcoin	HS (250 de zile)	33	0,123	0,458	126	0,912	0,3633
	GARCH(1,1)-t	22	0,543	0,189	128	0,770	0,3587
	Chronos-2, brut	31	0,242	0,402	134	0,404	0,3591
	Chronos-2 + conformal	21	0,413	0,170	120	0,657	0,3614

- Depășiri așteptate: S&P 500 17,2 (1 %) și 85,9 (5 %) în 1 717 zile; Bitcoin 25,0 și 124,8 în 2 496 de zile (tranzacționat zilnic).
- Valoare p verde: acoperirea nu este respinsă la 10 %; roșie: este respinsă. Pierderea tick = pierderea pinball la $\tau = 0{,}05$ (mai mică este mai bine).

(calcul propriu; Kupiec, 1995; Christoffersen, 1998)

Exerciții practic: notebook §9

Prognozele cuantilelor cu modele de limbaj și cu modele de serii de timp

- **Calea modelului lingvistic mare (LLM)** (cursul 12)
  - Randamentele sînt scrise ca text într-un prompt; un model general răspunde cu un număr
  - LLM-VaR și, pentru pierderea așteptată în coada distribuției (ES), LLM-ES, ale grupului nostru: zero-shot, fără ajustare fină (Pele et al., 2026)
- **Calea modelului fundație pentru serii de timp** (acest curs)
  - Numerele intră ca petice scalate; ieșirea este un set de cuantile
  - Mai ieftin pe prognoză, rulează local, calibrat aici printr-o deplasare conformală
- **Reguli comune**
  - Testați pe date noi, numărați depășirile, testați independența, comparați cu GARCH și HS

Test 1: scurgerea de informație

- Un coleg adaugă consumul efectiv al României din ziua d la intrările prognozei de preț pentru ziua d, iar MAE scade
  - Puneți modelul în producție?

Răspuns

- Nu: consumul efectiv din ziua d nu se cunoaște la ora 12:00 din ziua $d-1$
  - Folosiți prognoza operatorului sau decalaje disponibile la închiderea licitației.

Test 2: lățimea conformală

- Banda brută de 80 % a lui Chronos-2 a acoperit 76,5 % din orele de test
  - Ce face pasul conformal cu lățimea ei și de ce?

Răspuns

- O modifică cu $\hat{Q}$, cuantila de nivel $(1-\alpha)$ a distanțelor recente în afara benzii: o lărgește dacă banda era prea îngustă și o îngustează dacă era prea largă (aici 60,03 $\rightarrow$ 63,89 EUR/MWh).

Test 3: testul Kupiec

- În 1 717 zile, o VaR de 1 % a avut de 3 ori numărul așteptat de depășiri
  - Valoarea p a testului Kupiec este mare sau mică?

Răspuns

- Mică: $\hat{\pi}$ este departe de α, deci LR_{uc} este mare și acoperirea se respinge
  - Modelul subestimează riscul.

Recapitulare

- Mai întîi reperele: naiv 27,74, LEAR 22,79 EUR/MWh
  - Cea mai mică MAE: Chronos-2 cu covariabile (20,41).
- Modelele fundație prognozează prețul și consumul fără reantrenare
  - Lungimea contextului și covariabilele sînt parametrii lor de ajustare.
- Semnificația, prin testul Diebold–Mariano pe pierderile zilnice
  - Mai multe rulări pentru fiecare rețea.
- Calibrarea conformală transformă cuantilele brute în benzi și VaR oneste
  - Testați retrospectiv cu Kupiec și Christoffersen.
- Urmează: modelele multimodale și sinteza cursului (cursul 14).

Cercetările grupului nostru

- **Patru generații de metode de prognoză a prețurilor energiei**: modele econometrice, învățare automată, LSTM și arhitecturi transformer, comparate pe piețele europene de energie, inclusiv preantrenarea și transferul învățării (Andrei, Velev, Toma, Pele & Lessmann, 2024, arXiv 2411.03372).
- **Avertizarea timpurie a vîrfurilor de preț**: modele explicabile de tip gradient boosting pe date orare din România
  - Prognoza sarcinii reziduale este principalul declanșator al avertizărilor (Andrei, Pele, Cramer, Amza & Diaconu, 2026, PICBE).
- **Explicabilitate pe mai multe orizonturi**: ce factori contează de la 0–6 ore pînă la două săptămîni și în ce regim de preț, România 2018–2024 (Andrei, Pele & Cramer, 2026, PICBE).
- **LLM-VaR și LLM-ES**: modele de limbaj generale produc, fără reantrenare, prognoze ale valorii expuse la risc și ale pierderii așteptate în coada distribuției (ES) pe baza unui prompt cu randamentele trecute (Pele et al., 2026, Expert Systems with Applications).
- **Avertizare timpurie pentru criptoactivele „zombie”**: învățarea automată prezice care criptoactive vor deveni inactive (Będowska-Sójka, Wójcik & Pele, 2026, North American Journal of Economics and Finance).
- Rezultatele sînt preluate din rezumatele lucrărilor; cifrele de pe celelalte slide-uri provin din datele noastre.

(Academia de Studii Economice din București, ASE; Academia Română, Institutul de Prognoză Economică, IPE)

Lecturi și resurse suplimentare

- **Chronos**, cod și modele: github.com/amazon-science/chronos-forecasting.
- **TimesFM**: github.com/google-research/timesfm.
- **epftoolbox**, reperul deschis al lui Lago et al. (2021): github.com/jeslago/epftoolbox.
- **Predicția conformală**, o introducere accesibilă: arXiv:2107.07511.
- **Forecasting: Principles and Practice**, ed. a 3-a: otexts.com/fpp3.
- **Acest curs**: notebook, seminar și Quantlets — github.com/danpele/NEURAL_BIZ.

Bibliografie (1/2)

- Andrei, A.-V., Pele, D.-T., Cramer, A.-A., Amza, A. & Diaconu, D. (2026). Explainable AI-based early warning system for electricity price spikes: Evidence from the Romanian market. *Proceedings of the International Conference on Business Excellence*, 20(1), 4820–4836. doi:10.2478/picbe-2026-0352
- Andrei, A.-V., Pele, D.-T. & Cramer, A.-A. (2026). Multi-horizon explainability in energy price forecasting: Disentangling market dynamics and renewable intermittency in Romania's liberalized electricity market. *Proceedings of the International Conference on Business Excellence*, 20(1), 104–117. doi:10.2478/picbe-2026-0014
- Andrei, A.-V., Velev, G., Toma, F.-M., Pele, D. T. & Lessmann, S. (2024). Energy price modelling: A comparative evaluation of four generations of forecasting methods. arXiv:2411.03372
- Ansari, A. F. et al. (2024). Chronos: Learning the language of time series. *Transactions on Machine Learning Research*. arXiv:2403.07815
- Ansari, A. F. et al. (2025). Chronos-2: From univariate to universal forecasting. arXiv:2510.15821
- Będowska-Sójka, B., Wójcik, P. & Pele, D. T. (2026). Early warning systems for cryptocurrency markets: Predicting 'zombie' assets using machine learning. *The North American Journal of Economics and Finance*, 81, 102543. doi:10.1016/j.najef.2025.102543
- Christoffersen, P. F. (1998). Evaluating interval forecasts. *International Economic Review*, 39(4), 841–862. doi:10.2307/2527341
- Das, A., Kong, W., Sen, R. & Zhou, Y. (2024). A decoder-only foundation model for time-series forecasting. *Proceedings of the 41st International Conference on Machine Learning*. arXiv:2310.10688
- Diebold, F. X. & Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 13(3), 253–263. doi:10.1080/07350015.1995.10524599
- Kupiec, P. H. (1995). Techniques for verifying the accuracy of risk measurement models. *The Journal of Derivatives*, 3(2), 73–84. doi:10.3905/jod.1995.407942

Bibliografie (2/2)

- Lago, J., Marcjasz, G., De Schutter, B. & Weron, R. (2021). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. *Applied Energy*, 293, 116983. doi:10.1016/j.apenergy.2021.116983
- Nie, Y., Nguyen, N. H., Sinthong, P. & Kalagnanam, J. (2023). A time series is worth 64 words: Long-term forecasting with transformers. *International Conference on Learning Representations*. arXiv:2211.14730
- Oreshkin, B. N., Carpov, D., Chapados, N. & Bengio, Y. (2020). N-BEATS: Neural basis expansion analysis for interpretable time series forecasting. *International Conference on Learning Representations*. arXiv:1905.10437
- Pele, D. T., Bolovăneanu, V., Lin, M.-B., Ren, R., Ginavar, A. T., Spilak, B., Andrei, A.-V., Toma, F.-M., Lessmann, S. & Härdle, W. K. (2026). In the beginning was the Word: LLM-VaR and LLM-ES. *Expert Systems with Applications*, 295, 128676. doi:10.1016/j.eswa.2025.128676
- Romano, Y., Patterson, E. & Candès, E. (2019). Conformalized quantile regression. *Advances in Neural Information Processing Systems*, 32. arXiv:1905.03222
- Salinas, D., Flunkert, V., Gasthaus, J. & Januschowski, T. (2020). DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36(3), 1181–1191. doi:10.1016/j.ijforecast.2019.07.001
- Uniejewski, B., Weron, R. & Ziel, F. (2018). Variance stabilizing transformations for electricity spot price forecasting. *IEEE Transactions on Power Systems*, 33(2), 2219–2229. doi:10.1109/TPWRS.2017.2734563
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030–1081. doi:10.1016/j.ijforecast.2014.08.008
- Ziel, F. & Weron, R. (2018). Day-ahead electricity price forecasting with high-dimensional structures: Univariate vs. multivariate modeling frameworks. *Energy Economics*, 70, 396–420. doi:10.1016/j.eneco.2017.12.016

Anexa A: garanția de acoperire a benzii conformale

- Fie $s_1, \ldots, s_n, s_{n+1}$ scoruri de conformitate interschimbabile
  - Rangul lui s_{n+1} printre ele este uniform pe $\{1, \ldots, n+1\}$.
- De aici $\Pr(s_{n+1} \leq s_{(k)}) \geq k/(n+1)$
  - Alegînd $k = \lceil (n+1)(1-\alpha) \rceil$ obținem $\Pr(s_{n+1} \leq \hat{Q}) \geq 1-\alpha$.
- $s_{n+1} \leq \hat{Q}$ este echivalent cu $y_{n+1} \in [\hat{q}^{\alpha/2} - \hat{Q}, \hat{q}^{1-\alpha/2} + \hat{Q}]$, adică banda.
- Orele unei serii de prețuri sînt dependente și au derivă
  - Fereastra glisantă de 60 de zile renunță la exactitate în favoarea adaptării.

(Romano, Patterson & Candès, 2019)

Anexa B: testul de independență al lui Christoffersen

- Numărăm tranzițiile șirului de depășiri: n_{ij} = numărul de zile cu $I_{t-1} = i$ și $I_t = j$
  - $\hat{\pi}_{01} = n_{01}/(n_{00} + n_{01})$, $\hat{\pi}_{11} = n_{11}/(n_{10} + n_{11})$.
- $\mathrm{LR}_{ind} = -2 \ln \frac{(1-\hat{\pi})^{n_{00}+n_{10}} \hat{\pi}^{n_{01}+n_{11}}}{(1-\hat{\pi}_{01})^{n_{00}} \hat{\pi}_{01}^{n_{01}} (1-\hat{\pi}_{11})^{n_{10}} \hat{\pi}_{11}^{n_{11}}} \sim \chi^2_1$.
- O valoare p mică înseamnă că depășirile vin grupat: modelul reacționează prea încet la un șoc de volatilitate.

(Christoffersen, 1998)

Anexa C: detalii de implementare

- LEAR: LassoLarsIC din scikit-learn (criteriul AIC), intrări standardizate, reestimare zilnică pe 1 092 de zile.
- DNN și N-BEATS: PyTorch, pierdere L1, Adam, oprire timpurie
  - Valorile generatorului aleator: 20261108 și următoarele.
- Modelele fundație: amazon/chronos-2, amazon/chronos-bolt-base, google/timesfm-2.5-200m-pytorch de pe Hugging Face, doar inferență
  - Rularea completă a durat 2,7 minute pe un laptop.
- Orele urmează calendarul CET
  - Ora dublă din toamnă este mediată
  - Zilele cu o oră lipsă sînt excluse din țintele de antrenare și din test.