

Academia Oamenilor de Știință din România

Ilfov 3, 050044 București, Romania



RAPORT INTERMEDIAR DE CERCETARE

Iulie 2025

Proiect de cercetare:

” Îmbunătățirea prognozelor ratei inflației în România folosind analiza de sentiment și machine learning (învățare automată)”

Director de proiect: Prof. univ. dr. habil. CS I Mihaela Simionescu

Academia Oamenilor de Știință din România, Ilfov 3, 050044 București, Romania

Universitatea din București

E-mail: mihaela.simionescu@unibuc.ro, mihaela.simionescu@faa.unibuc.ro

Telefon: + 40 748 112 411

Cercetător: dr. CS III Alexandru-Sabin Nicula

Academia Oamenilor de Știință din România, Ilfov 3, 050044 București, Romania

Universitatea Babeș-Bolyai

E-mail: sabin.nicula@ince.ro

Telefon: + 40 749 980 159

Prezentul raport intermediar include un studiu corelat cu tema proiectului împreună cu articolul corespunzător publicat într-o revistă WoS, autorii având afilierea AOSR.

Diseminarea rezultatelor cercetării

Articole publicate în reviste WoS

1. Simionescu Mihaela, Nicula Alexandru-Sabin (2024). Sentiment Analysis as Innovation in the Inflation Forecasting in Romania. Marketing and Management of Innovations, 15(2), 13–25, ISSN (print) – 2218-4511, ISSN (online) – 2227-6718, WOS:001254017400002, IF =1.2, AIS=0.101, <https://doi.org/10.21272/mmi.2024.2-02>.
https://mmi.sumdu.edu.ua/wp-content/uploads/2024/06/02_A809-2024_Simionescu-et-al.pdf
2. Simionescu Mihaela, Alexandru- Sabin Nicula (2025). The role of sentiment analysis and central bank interest rate decisions in forecasting inflation: A Bayesian non-parametric approach for Czech Republic and Romania, Romanian Statistical Review, nr. 1 / 2025, 3-24, WOS:001495208700001, ISSN Print: 1018-046X, ISSN Online: 1844-7694, IF=0.2, AIS=0.021.
https://www.revistadestatistica.ro/wp-content/uploads/2025/05/A1_RRS_1_2025.pdf
3. Simionescu Mihaela (2025). Machine Learning vs. Econometric Models to Forecast Inflation Rate in Romania? The Role of Sentiment Analysis, Mathematics, 13(1), 168, 1-18, WOS:001393595400001, EISSN 2227-7390, IF=2.2, AIS=0.373, <https://doi.org/10.3390/math13010168>
<https://www.mdpi.com/2227-7390/13/1/168>
4. **Simionescu Mihaela**, Oancea Bogdan (2025). Does Income Inequality Influence Energy Consumption in the European Union?, Energies, 18(4), 787, 1-19, WOS:001431612400001, ISSN: 1996-1073, IF=3.2, AIS=0.470, <https://doi.org/10.3390/en18040787>
<https://www.mdpi.com/1996-1073/18/4/787>
5. **Simionescu Mihaela**, Oancea Bogdan (2025). Income/gender inequality and energy use in the European Union, Energy Efficiency, 18(32), 1-21, WOS:001458340700001, Electronic ISSN1570-6478, Print ISSN 1570-646X, IF=2, AIS=0.396, <https://doi.org/10.1007/s12053-025-10314-4>

https://link.springer.com/article/10.1007/s12053-025-10314-4?utm_source=rct_congratemail&utm_medium=email&utm_campaign=oa_20250402&utm_content=10.1007/s12053-025-10314-4

6. **Simionescu Mihaela**, Cifuentes-Faura Javier (2025). Empirical Insights on Inflation, Financial Development and Income Inequality in Central and Eastern European Countries, Czech Journal of Economics and Finance, 75 (1), 29-58, WOS:001459891400002, Print ISSN 0015-1920, Online ISSN 2464-7683, în Q4 după factorul de impact, IF=0.7, AIS=0.082, <https://doi.org/10.32065/CJEF.2025.01.02>
https://journal.fsv.cuni.cz/storage/1544_attachment.pdf
7. **Simionescu Mihaela**, Constantin Daniela-Luminița, Marin Erika (2025). The impact of demographic dynamics on income inequality at regional level: the intriguing case of Romania, Management Research and Practice, 17(1), 5-17, WOS:001439963800001, ISSN: 2067-2462, IF=0.6, AIS=0.064.
<https://mrp.ase.ro/v17i1/1.pdf>
8. Simionescu Mihaela (2025). The Impact of Income Inequality on Energy Poverty in the European Union, International Journal of Financial Studies, 13(2), 54, 1-29, EISSN 2227-7072, IF=2.2, AIS=0.319.
<https://doi.org/10.3390/ijfs13020054>
<https://www.mdpi.com/2227-7072/13/2/54>

Articol publicat în Journal of Knowledge Dynamics (revista AOSR)

Simionescu Mihaela (2025). The Impact of Inflation Rate on Income Inequality in Romania, Journal of Knowledge Dynamics, 2(1), 19-32, ISSN Online 3061-2640.
<https://doi.org/10.56082/jkd.2025.2.19>
<https://www.aos.ro/wp-content/anale/JKDVol2Nr1Art.2.pdf>

Rolul analizei sentimentului și al majorării dobânzii de către Banca Centrală în prognoza inflației din Cehia și România utilizând modele Bayesiene neparametrice

1. Introducere

Războiul din Ucraina a avut un impact semnificativ asupra inflației din UE, determinând niveluri record ale ratei inflației în anul 2022. Mai multe țări din UE au experimentat hiperinflație în 2022, statele baltice și unele țări din Europa de Est confruntându-se adesea cu cele mai ridicate niveluri. În acest context dominat de incertitudine, obiectivul de a furniza prognoze precise ale inflației devine mai dificilă ca niciodată.

Prognozele inflației cu acuratețe ridicată sunt cruciale pentru actorii economici, în special în perioade de schimbări semnificative ale inflației. În primul rând, prognozele inflației influențează direct politica monetară și alte politici economice, având un impact asupra cadrului economic general. În al doilea rând, băncile centrale se bazează pe prognoze precise pentru a proiecta reacții adecvate și în timp util la schimbările inflației, direcționând în cele din urmă inflația înapoi la nivelurile țintă. În al treilea rând, companiile utilizează prognozele inflației pentru a anticipa schimbările pieței și a lua decizii informate (Joseph et al., 2022).

Având în vedere acest context economic recent și necesitatea de a-l depăși și de a furniza prognoze precise, obiectivul principal al acestui studiu este de a propune prognoze precise ale inflației pentru România și Cehia pe orizontul 2023: T1 - 2023: T4, două țări din estul Europei care au fost profund afectate de inflație. Este considerat doar un orizont de prognoză scurt, deoarece cercetarea abordează o perioadă specifică dominată de războiul din Ucraina, care a generat o inflație ridicată. Mai mult, capacitatea diferitelor metode de a genera prognoze precise este verificată doar în contextul specific în care anul anterior orizontului de prognoză este caracterizat de hiperinflație, iar băncile centrale au implementat în acel an strategii bazate pe creșterea ratei dobânzii.

Propunerea de prognoze cu acuratețe ridicată depinde de mulți factori, metodele de prognoză și intervențiile băncilor centrale fiind cruciale. Prin urmare, acest studiu se bazează pe modele neparametrice care sunt mai potrivite pentru captarea neliniarităților. În plus, eficiența strategiei băncilor de a controla inflația prin creșterea ratei dobânzii este analizată în profunzime într-o formă comparativă folosind estimatori diferențe-în-diferențe, inclusiv abordarea care se adresează impactului asupra componentelor inflației (inflație așteptată/neașteptată). Din acest punct de vedere, principala întrebare de cercetare abordează necesitatea de a obține prognoze precise ale inflației prin selectarea celei mai bune metode de predicție și a celei mai bune strategii de control al inflației.

Doar câteva studii au utilizat modele neparametrice pentru a prezice inflația, presupunând o conexiune liniară sau neliniară. De exemplu, relația neliniară dintre inflație și diverși predictorii poate fi captată prin utilizarea proceselor gaussiene și Dirichlet (Clark et al., 2022). Un model ascuns Markov infinit de tip sticky a fost folosit de Jochmann (2014) pentru a explica rata inflației din SUA. Din acest punct de vedere, noutatea acestui studiu se bazează pe contribuția la prognoza empirică prin implementarea unor abordări neparametrice adecvate. În primul rând, cercetarea propune modele Bayesiene neparametrice pentru prognoza inflației (model de regresie liniară

Bayesiană, model de regresie liniară Bayesiană cu prior LASSO și model de regresie liniară Bayesiană cu selecție stochastică a variabilelor (SSVS)). Mai mult, se folosesc și regresii generalizate de rețele neuronale (GRNN) pentru a face prognoze, iar evaluarea preciziei prognozelor ne permite să determinăm cele mai bune predicții.

Ca o noutate pentru prognoza empirică a inflației, aceste metode captează opiniile experților din băncile centrale cu privire la evoluția viitoare a inflației prin introducerea indicelui de sentiment ca variabilă explicativă în modele. Analiza sentimentului este din ce în ce mai recunoscută ca un instrument util pentru previzionarea inflației. Această abordare a fost utilizată anterior pentru a prezice rata inflației în România folosind tehnici de învățare automată (Simionescu, 2022). Ca o noutate pentru literatură, software-ul IntelliDockers este utilizat pentru a calcula indicii de sentiment pe baza rapoartelor oficiale ale băncilor centrale din Cehia și România.

Acuratețea previziunilor depinde, de asemenea, de efectele viitoare anticipate ale strategiei băncii centrale de a reduce inflația. Acest studiu face un pas înainte în contextul specific al economiilor românești și cehe din perioada de hiperinflație generată de războiul din Ucraina și de factori interni. Strategia bazată pe creșterea ratei dobânzii a fost aplicată diferit de cele două state: banca cehă a făcut o creștere bruscă a ratei dobânzii, în timp ce BNR a adoptat o creștere treptată a ratei dobânzii. Este clar că inflația din Republica Cehă a scăzut mai mult, în timp ce România a gestionat mai bine inflația la începutul anului 2024. Prin urmare, se aplică o abordare a estimatorului diferență-în-diferențe pentru a evalua contribuția strategiei cehe la controlul inflației în comparație cu cazul în care ar fi fost aplicată strategia românească. Mai mult, o analiză mai aprofundată verifică ce componentă a inflației a fost vizată de această strategie (inflație așteptată / neașteptată). Această analiză suplimentară ne permite să înțelegem de ce prognozele furnizate de banca națională a Cehiei au fost mai performante. Rezultatele au confirmat capacitatea modelului de regresie liniară Bayesiană care utilizează indicele sentimentului și rata dobânzii ca predictor pentru a furniza cele mai bune prognoze pentru ambele țări. Previziunile făcute pentru Cehia au avut o acuratețe mai mare, deoarece strategia sa de control a inflației a fost mai eficientă. Cu toate acestea, strategia a redus inflația așteptată, dar nu a avut un impact semnificativ asupra inflației neașteptate.

În ansamblu, contribuțiile acestui studiu constau în utilizarea unor abordări neparametrice diverse care sunt mai potrivite pentru modelarea inflației, utilizarea analizei sentimentului pentru a capta opiniile experților cu privire la evoluția viitoare a inflației, evaluarea preciziei prognozei și a informațiilor privind mecanismele de îmbunătățire a previziunilor prin evaluarea impactului strategiilor implementate de băncile centrale din Cehia și România pentru controlul inflației, inflației așteptate și inflației neașteptate, utilizând estimatori diferență-în-diferențe. Aceste contribuții reprezintă un pas înainte în conceperea celor mai bune propuneri de politici pentru controlul inflației în viitor.

Toate aceste contribuții sunt integrate în raportul de cercetare care urmează o structură canonică. După această introducere, sunt prezentate câteva informații din literatura de specialitate, cu accent principal pe metodele neparametrice. Secțiunile următoare ale raportului descriu metodologia, datele, rezultatele cu discuții și propun concluzii pertinente.

2. Literatura de specialitate

Numeroase metode au fost utilizate în literatura de specialitate pentru previzionarea inflației, cele mai utilizate fiind: modele bazate pe curba Phillips (Dotsey et al., 2018), modele univariate cu componente neobservate (Stock et al., 2016), modele DSGE (Cardani et al., 2022), agregarea previziunilor (Hubrich, n.d.), modele VAR de tip Bayesian (Cimadomo et al., 2022), reducerea dimensionalității (Kim și Swanson, 2008). Majoritatea acestor metode presupun o relație liniară între inflație și alte variabile, chiar dacă o relație neliniară sau neparametrică ar fi mai potrivită în anumite cazuri. În timp ce cea mai mare parte a cercetării privind previzionarea ratei inflației s-a concentrat pe modele liniare, un volum din ce în ce mai mare de lucrări explorează abordări neliniare și neparametrice.

Există și varianta curbelor Phillips neliniare. Unele studii sugerează că relația dintre activitatea economică și inflație ar putea fi neliniară, cu efecte mai puternice care apar în perioade de creștere economică ridicată (Babb și Detmeister, 2017). Rezultatele furnizate de modelele liniare și neliniare sunt diferite, cel puțin pentru câțiva ani.

Cercetările recente evidențiază potențialul tehnicilor de învățare automată (*machine learning*- ML), în special *random forests* (RF, pădurile aleatoare) (Breiman, 2001), pentru elaborarea de previziuni macroeconomice precise, inclusiv pentru inflație (Medeiros et al., 2021). Aceste metode au furnizat rezultate bune chiar și în perioade de criză economică. Medeiros et al. (2021) au investigat potențialul metodelor de învățare automată pentru prognozarea inflației din SUA. Spre deosebire de rezultatele din cercetările anterioare, autorii demonstrează că modelele ML care utilizează un număr mare de variabile de control depășesc performanțele previziunilor cu care se compară. Dintre acestea, modelul RF se remarcă prin acuratețea sa superioară. Acest succes este atribuit abordării sale specifice de selecție a variabilelor și potențialului pentru relații neliniare între variabilele macroeconomice din trecut și inflație. Un alt studiu a investigat eficacitatea diferitelor tehnici de învățare automată pentru prognozarea inflației în Nigeria. Analiza a comparat regresia ridge și rețelele neuronale artificiale (ANN- *artificial neural networks*) cu alte metode precum LASSO și PLS. Rezultatele au arătat că regresia ridge și ANN au depășit semnificativ celelalte modele în ceea ce privește acuratețea prognozei (Medeiros et al., 2021). În plus, studiul a identificat factorii cheie ai inflației din Nigeria, inclusiv inflația bunurilor alimentare, inflația de bază și rata dobânzii interbancare.

Dincolo de metodele tradiționale, tehnicile Bayesiene oferă alternative performante. Jochmann (2015) propune un model Markov ascuns infinit pentru a analiza dinamica inflației din SUA, identificând un declin secular al volatilității și regimuri distincte ale inflației. Clark et al. (2021) utilizează modele de arbori de regresie aditivă Bayesiană (BART) pentru prognozarea inflației, demonstrând performanțe îmbunătățite în perioade volatile precum pandemia de COVID-19. Cu toate acestea, o limitare potențială a BART și a altor tehnici neparametrice (de exemplu, procesele gaussiene) constă în ipoteza șocurilor gaussiene. Dacă dovezile empirice sugerează caracteristici care nu sunt gaussiene, cum ar fi cozi lungi în inovații, flexibilitatea modelului poate duce la capturarea acestor caracteristici în cadrul mediei condiționale, ceea ce poate duce la o reprezentare greșită a relațiilor neliniare adevărate dintre dinamica inflației și factorii săi predictivi.

Tierney (2019) extinde domeniul prognozelor neparametrice prin introducerea a trei metode locale neparametrice noi. Aceste metode sunt special concepute pentru modelul neparametric de excludere din persistența inflației de bază și pot valorifica datele revizuite în timp real privind cheltuielile personale de consum (CPC) și CPC de bază pentru 62 de serii de date. Previzionarea neparametrică locală oferă mai multe avantaje: a) flexibilitatea datelor: permite o

analiză mai nuanțată prin încorporarea perioadelor cu inflație scăzută în alte segmente cu inflație scăzută și invers. b) detectarea anomaliilor în timp real: când sunt aplicate pe date în timp real, aceste modele pot ajuta factorii de decizie politică să identifice potențiale anomalii, evenimente economice anormale sau inconsistențe ale datelor, cum ar fi schimbările de volatilitate. Cea mai eficientă metodă dintre cele trei este a treia. Aceasta valorifică flexibilitatea abordării neparametrice prin realizarea de previziuni condiționate de valoarea prezisă, permițând analiza contrafactuală.

O atenție deosebită a fost acordată comparațiilor între modelele econometrice și rețelele neuronale, care sunt și subiectul acestui studiu. Studiul lui Moshiri și Cameron (2000) investighează eficacitatea modelelor de rețele neuronale artificiale cu propagare inversă (BPN) pentru prognozarea inflației, comparându-le cu abordările econometrice tradiționale. Principalele avantaje ale modelelor BPN sunt capacitatea lor de a gestiona relații complexe și independența față de ipoteza de liniaritate utilizată în mod obișnuit în metodele tradiționale. Studiul compară modelele BPN cu patru modele econometrice: un model structural în formă redusă, un model ARIMA, un model vectorial-autoregresiv și un model de vectorial-autoregresiv de tip Bayesian. Fiecare model econometric este asociat cu un model BPN hibrid folosind același set de variabile. Apoi, se generează previziuni dinamice pentru trei orizonturi: cu o lună, cu trei luni și cu 12 luni înainte. Calitatea previziunilor este evaluată folosind erori pătratic medii și erori absolute medii. Rezultatele demonstrează că modelele BPN hibride funcționează similar cu toate modelele econometrice tradiționale și chiar le depășesc în anumite cazuri. Un alt studiu a comparat eficacitatea rețelelor neuronale artificiale (ANN) și a modelului de tip mers aleator pentru prognozarea inflației în 28 de țări membre ale OCDE (Choudhary, 2012). Pentru predicțiile pe termen scurt, ANN au fost mai precise în 45% din țări, în timp ce modelul de tip mers aleator a fost mai bun în 23% dintre cazuri. În plus, combinarea mai multor modele ANN s-a dovedit a fi o abordare promițătoare pentru prognozarea inflației.

Alte lucrări au investigat dacă un anumit tip de rețea neuronală, modelul de memorie pe termen lung și scurt (LSTM), ar putea îmbunătăți prognozele inflației în comparație cu alte metode. Analizând inflația lunară din SUA, Almosova și Andresen (2023) au constatat că LSTM a depășit ușor modelele tradiționale precum cel autoregresiv (AR), rețelele neuronale de bază (NN) și modelele cu schimbare Markov. Cu toate acestea, performanța sa a fost comparabilă cu modelul autoregresiv sezonier (SARIMA), sugerând o acuratețe similară. În plus, autorii au analizat sensibilitatea modelului la diferite setări și au explorat modul în care rețeaua învață printr-o tehnică nouă.

Pentru o cunoaștere în detaliu a mecanismelor inflației, alte studii s-au concentrat pe componentele individuale din cadrul indicelui prețurilor bunurilor de consum (IPC), în plus față de inflația totală. De exemplu, a fost introdusă o abordare nouă pentru predicția inflației (modelul de rețea neuronală recurentă ierarhică - HRNN), care valorifică informațiile de la niveluri superioare ale ierarhiei IPC pentru a îmbunătăți predicțiile la niveluri inferioare mai volatile (Barkan et al., 2023).

3. Metodologie și date

În primul rând, prognozele inflației se realizează folosind modele Bayesiene neparametrice: modelul de regresie liniară Bayesiană, modelul de regresie liniară Bayesiană cu distribuție a priori LASSO și modelul de regresie liniară Bayesiană cu selecție stochastică a variabilelor (SSVS). Valorile a priori utilizate în acest studiu sunt selectate pornind de la valori inițiale indicate de Karabatsos (2018). Se testează mai multe combinații pentru a păstra modelul cu cel mai mare coeficient de determinare (R-pătrat). În al doilea rând, prognozele inflației se realizează și folosind regresii generalizate de rețele neuronale (GRNN) care sunt implementate în R folosind pachetul *tsfgrnn*. Cele două tipuri de metode de prognoză sunt descrise în această secțiune.

Se pornește de la forma generală a unei regresii liniare Bayesiene:

$$y_t = \sum_{k=1}^p \beta_k x_{tk} + \varepsilon_t, k=1,2,\dots,p$$

β_k - parametru (coeficient);

ε_t - eroare

σ^2 - varianța erorii

Modelul de regresie liniară Bayesiană

$$y_t|x_t \sim f(y|x_t), t = 1,2, \dots, n$$

$$f(y|x) = n(y|x^T \beta, \sigma^2)$$

$$\beta_0 \propto 1$$

$$\beta_k|\sigma^2 \sim N(0, \sigma^2 v_\beta), k=1,2,\dots,p$$

$$\sigma^2 \sim IG(a_0/2, a_0/2)$$

Se consideră $v_\beta=1000$ și $a_0=0,001$.

Modelul de regresie liniară Bayesiană cu distribuție a priori LASSO

$$y_t|x_t \sim f(y|x_t), t = 1,2, \dots, n$$

$$f(y|x) = n(y|x^T \beta, \sigma^2)$$

$$\beta_0 \propto 1$$

$$(\beta_k)_{k=1}^p | \lambda, \sigma^2 \sim \prod_{k=1}^p \text{Laplace}(\beta_k | 0, \sigma/\lambda)$$

$$\lambda \sim \text{Gamma}(\lambda|r, \delta)$$

$$\sigma^2 \sim \text{IG}(\sigma^2|0,0)$$

Se consideră $r=1$ și $\delta=2$.

Modelul de regresie liniară Bayesiană cu selecție stochastică a variabilelor (SSVS)

$$y_t|x_t \sim f(y|x_t), t = 1, 2, \dots, n$$

$$f(y|x) = n(y|x^T \beta, \sigma^2)$$

$$\beta_0 \propto 1$$

$$\beta_k|\sigma^2, \gamma_k \sim N(0, \sigma^2\{v_1\gamma_k + v_0(1 - \gamma_k)\})$$

$$\gamma_k \sim \text{Ber}(w_\gamma), k = 1, \dots, p$$

$$\sigma^2 \sim \text{IG}(a_0/2, \lambda a_0/2)$$

Se consideră $v_1 = 1$, $v_0 = 0.1$, $w_\gamma = 0.5$, $a_0 = 3$, $\lambda = 14$.

Regresii generalizate de rețele neuronale (GRNN)

O rețea neuronală generalizată de regresie (GRNN) este o rețea cu funcție radială de bază (RBF) cu o singură învățare rapidă. Include un strat ascuns format din neuroni RBF. Numărul de neuroni din stratul ascuns este egal cu numărul de exemple de antrenament. Centrul neuronului este reprezentat de exemplul de antrenament corespunzător. Ieșirea neuronului este o măsură a distanței dintre exemplul de antrenament și vectorul de intrare. Neuronul se bazează pe o funcție Gaussiană multivariată, unde x este vectorul de intrare, x_t este centrul neuronului și σ este parametrul de netezire:

$$G(x, x_t) = e^{-\frac{\|x-x_t\|^2}{2\sigma^2}}$$

Parametrul de netezire reflectă numărul de ținte relevante pentru media ponderată. Când ponderile sunt similare, rezultatul are o valoare în jurul mediei țintelor de antrenament, iar aceasta are loc când parametrul de netezire este mare. În cazul unei valori mici a acestui parametru, ponderi semnificative sunt atribuite doar țintelor de antrenament care sunt apropiate vectorului de intrare.

Luând în considerare n modele de antrenament care formează un set de antrenament dat de vectorul $\{x_1, x_2, \dots, x_n\}$ și n ținte, date de scalari $\{y_1, y_2, \dots, y_n\}$, trebuie luați în considerare doi pași pentru a calcula ieșirea cunoscând modelul de intrare x .

Pașul 1: calculul ponderilor care reprezintă o măsură a apropierii lui x de modelele de antrenament;

$$\omega_t = \frac{e^{-\frac{\|x-x_t\|^2}{2\sigma^2}}}{\sum_{j=1}^n e^{-\frac{\|x-x_j\|^2}{2\sigma^2}}}$$

Proprietățile ponderilor: acestea scad odată cu distanța față de modelul de antrenament; suma lor este unu și reprezintă contribuția fiecărui model de antrenament la ieșirea finală.

Pasul 2: calculul stratului de ieșire GRNN ca medie ponderată a țintelor de antrenament.

$$\hat{y} = \sum_{t=1}^n \omega_t y_t$$

Indicele sentimentului și rata dobânzii din politica monetară sunt utilizate ca variabile exogene pentru a explica rata inflației în modelele Bayesiene neparametrice. Calculul indicelui sentimentului se bazează pe procesarea limbajului natural (NLP), utilizându-se software-ul IntelliDockers. Acest program utilizează rețele neuronale recurente, un algoritm specific pentru învățarea automată. Previziunile trimestriale ale ratei inflației și valorile reale pentru România sunt furnizate de Rapoartele asupra Inflației publicate de Banca Națională a României.

Textul din secțiunea *Perspectivile inflației* din rapoartele trimestriale ale inflației este introdus în IntelliDockers pentru a calcula indicele sentimentului pentru perioada 2006: T1-2022: T4. Metodele de prognoză propuse sunt utilizate pentru a predica rata inflației pe orizontul 2023: T1-2023: T4.

Previziunile pentru rata inflației în Cehia sunt publicate în *Rapoartele de Politică Monetară* pentru fiecare sezon (iarnă, primăvară, vară și toamnă) din 2021. Având în vedere previziunile trimestriale scurte ale inflației din aceste rapoarte, previziunile lunare ale inflației au fost luate din rapoartele lunare numite *Perspective Economică Globală*. Rata inflației trimestriale este calculată ca medie a ratelor inflației lunare corespunzătoare. Indicele sentimentului trimestrial este calculat ca medie a indicilor sentimentului pentru lunile corespunzătoare, utilizând rapoartele în limba engleză și textul disponibil în secțiunile *Inflație* sau *Focus*, în funcție de structura rapoartelor. Indicele sentimentului lunar este calculat folosind IntelliDockers și textul din *Rapoartele de Politică Monetară* pentru perioada ianuarie: 2011 - decembrie: 2022.

Rata inflației cu frecvență trimestrială în Cehia este furnizată de Banca Federală a Rezervei din St. Louis, iar rata dobânzii de politica monetară este furnizată de Banca Națională a Cehiei.

Statisticile descriptive pentru rata inflației prezentate în Tabelul 1 sugerează că rata inflației tinde să fie mai mică în Cehia comparativ cu România. Cea mai mare rată a inflației a fost observată în România la sfârșitul perioadei analizate (2022: T4) din cauza șocurilor post-pandemice și a războiului din Ucraina. Pe de altă parte, Cehia a înregistrat cea mai mare inflație în primul trimestru al anului 2022. Războiul din Ucraina a perturbat piața globală a energiei, determinând creșterea prețurilor. Deoarece Cehia se bazează puternic pe importurile de energie, a resimțit acest impact mai acut. Dincolo de problema globală, unii susțin că factorii interni din Republica Cehă, cum ar fi dinamica salariilor și a marjelor interne, au jucat un rol în amplificarea inflației în comparație cu alte țări din regiune. Ipoteza distribuției normale nu este susținută pentru niciuna dintre seriile de timp.

Tabelul 1. Statistici descriptive pentru rata inflației

Statistici	România	Cehia
Media	4,91%	0,93%
Maxim	16,4%	6,27%
Minimu	-1,70%	-0,49%
Abaterea standard	3,78%	1,51%
Testul Shapiro-Wilk	5,391 (<0,01)	8,89 (<0,01)

Sursa: calcule proprii.

4. Rezultate și discuții

Seriile de timp au fost ajustate sezonier, iar prezența rădăcinii unitare a fost verificată pentru fiecare serie utilizând testul de rădăcină unitate cu întreruperi în structura seriilor. Rezultatele din Tabelul 2 susțin ipoteza conform căreia toate seriile de timp inițiale sunt staționare la un nivel de semnificație de 5%.

Tabelul 2. Rezultatele testului de rădăcină unitate cu întreruperi în structura seriilor

Țara	Variabila	Serii de timp	Stat.	Valoarea p	Decizia
Romania	Rata inflației	Seria în dublă diferență	-13.3	<0.01	fără rădăcină unitate
		Seria în primă diferență	-8.3	<0.01	fără rădăcină unitate
		Seria în nivel	-4.8	0.02	fără rădăcină unitate la un nivel de semnificație de 5%
	Indicele de sentiment	Seria în dublă diferență	-20.6	<0.01	fără rădăcină unitate
		Seria în primă diferență	-15.1	<0.01	fără rădăcină unitate
		Seria în nivel	-8.4	<0.01	fără rădăcină unitate
	Rata dobânzii	Seria în dublă diferență	-12.5	<0.01	fără rădăcină unitate

		Seria în primă diferență	-10.3	<0.01	fără rădăcină unitate
		Seria în nivel	-9.8	<0.01	fără rădăcină unitate
Cehia	Rata inflației	Seria în dublă diferență	-10.3	<0.01	fără rădăcină unitate
		Seria în primă diferență	-9.2	<0.01	fără rădăcină unitate
		Seria în nivel	-8.6	<0.01	fără rădăcină unitate
	Indicele de sentiment	Seria în dublă diferență	-20.4	<0.01	fără rădăcină unitate
		Seria în primă diferență	-16.3	<0.01	fără rădăcină unitate
		Seria în nivel	-9.9	<0.01	fără rădăcină unitate
	Rata dobânzii	Seria în dublă diferență	-11.8	<0.01	fără rădăcină unitate
		Seria în primă diferență	-9.7	<0.01	fără rădăcină unitate
		Seria în nivel	-8.9	<0.01	fără rădăcină unitate

Sursa: calcule proprii.

Rezultatele empirice din Tabelul 3 sugerează un impact negativ al indicelui de sentiment și al ratei dobânzii asupra inflației. Aceasta sugerează că pentru experții de la băncile naționale așteptările optimiste legate de evoluția evoluției s-au tradus în mai puțină inflație. Creșterea ratei dobânzii a contribuit la reducerea inflației în ambele țări.

Tabelul 3. Rezultatele estimărilor bazate pe modele de regresie Bayesiană neparametrică pe orizontul 2023: Q1-2023: Q4

Țara	Parametrii	Model de regresie liniară Bayesiană	Model de regresie liniară Bayesiană Cu distribuție a priori LASSO	Model de regresie liniară Bayesiană cu SSVS
România	Valori a priori ale parametrilor modelului	$v_{\beta} = 1000$ $a_0 = 0,001$	$r=1, \delta = 2$	$v_1 = 1, v_0 = 0,1, w_{\gamma} = 0,5, a_0 = 3, \lambda = 14$
		Media (abaterea standard în paranteze)		
	β_0	13,221 (2,793)	11,541 (2,843)	13,156 (2,256)
	$\beta_{sentiment}$	-12,006 (3,967)	-8,970 (4,165)	-11,914 (3,427)
	$\beta_{interest}$	-0,155 (0,243)	-0,179 (0,241)	-0,153 (0,192)

	λ	-	0,698 (0,297)	-
	$\lambda_{sentiment}$	-	-	0,986 (0,119)
	$\lambda_{interest}$	-	-	0,028 (0,164)
	σ^2	12,714 (2,25)	13,048 (2,303)	8,226 (1,098)
Cehia	β_0	5,663 (1,335)	4,221 (1,033)	5,558 (1,228)
	$\beta_{sentiment}$	-1,376 (0,456)	-0,995 (0,032)	-1,274 (0,337)
	$\beta_{interest}$	-1,003 (0,342)	-0,788 (0,223)	-0,995 (0,257)
	λ	-	0,557 (0,225)	-
	$\lambda_{sentiment}$	-	-	0,448 (0,206)
	$\lambda_{interest}$	-	-	0,142 (0,044)
	σ^2	5,667 (1,334)	4,556 (2,072)	3,221 (0,994)

Sursa: calcule proprii.

Sunt utilizate două strategii pentru a face prognoze cu mai mulți pași folosind GRNN:

- Strategia Multiple Input Multiple Output cunoscută sub numele de MIMO bazată pe antrenarea vectorilor ținte cu valori succesive ale seriei de timp predictate, dimensiunea unui vector fiind dată de lungimea orizontului de prognoză;
- Strategia recursivă.

Evaluarea acurateții prognozei raportată în Tabelul 4 arată că previziunile inflației pentru România pe baza modelelor neparametrice sunt mai bune decât cele bazate pe modele GRNN, conform MAPE și SMAPE. Testul DM confirmă, de asemenea, superioritatea modelelor neparametrice în comparație cu modelul GRNN cu strategie de prognoză recursivă. Pe de altă parte, toți indicatorii de acuratețe susțin ipoteza că modelele Bayesiene neparametrice care includ indicele de sentiment depășesc abordarea GRNN pentru orizontul 2023: T1-2023: T4. Modelul de regresie liniară Bayesiană a determinat cea mai bună prognoză pentru rata inflației în Cehia. Capacitatea modelelor Bayesiene neparametrice de a furniza previziuni precise ale inflației este susținută și de studiul lui Clark et al. (2022).

Tabelul 4. Acuratețea prognozei inflației pentru România și Republica Cehă

Țara	Metoda de prognoză	RMSE	MAE	MAPE	SMAPE	Testul DM (comparații cu previziunile bazate pe modelul GRNN-strategia recursivă)
România	Model de regresie liniară Bayesiană	4,918197	4,223005	0,3813077	0,4921606	14,30*

	Model de regresie liniară Bayesiană cu distribuție a priori LASSO	5,109041	4,391575	0,3969654	0,5168944	11,34*
	Model de regresie liniară Bayesiană cu SSVS	4,922759	4,226795	0,3816435	0,492689	14,28*
	Model GRNN–strategia MIMO	3,162278	3,000000	4,236205	4,338796	1,18
	Model GRNN–strategia recursivă	2,236068	2,000000	2,807458	2,857449	-
Cehia	Model de regresie liniară Bayesiană	2,343786	1,894773	0,296345	0,3227	7,89*
	Model de regresie liniară Bayesiană cu distribuție a priori LASSO	2,998453	2,673492	0,359827	0,383385	8,56*
	Model de regresie liniară Bayesiană cu SSVS	2,445889	2,036992	0,317559	0,364593	7,97*
	Model GRNN–strategia MIMO	4,783483	4,674593	5,045636	5,143844	1,87
	Model GRNN–strategia recursivă	3,349823	3,284595	3,884529	4,036738	-

Sursa: calcule proprii. * înseamnă valoarea p sub 0,01.

În cazul României, sigma (parametrul de netezire) este 0,2196321 pentru strategia recursivă și 0,1936133 pentru MIMO, în timp ce pentru Cehia valorile sunt 0,334223 și, respectiv, 0,2983467.

Pentru ambele țări au fost construite modele autoregresive de ordinul întâi (AR(1)) pentru a explica rata inflației în vederea determinării inflației așteptate și a celei neanticipate. Valorile estimate pe baza AR(1) reprezintă seria inflației așteptate, în timp ce reziduurile reflectă valorile inflației neanticipate. Rezultatele estimărilor sunt raportate în Tabelul 5.

Tabelul 5. Modele autoregresive utilizate pentru calculul inflației așteptate și neanticipate în Cehia și România (2011: T1-2024: T2)

	România				Cehia			
	Coeficient	Eroare standard	Stat. DW	Testul White	Coeficient	Eroare standard	Stat. DW	Testul White
Constanta	4.235**	1.975	1.93	7.49 (0.44)	0.886***	0.296	2.162	10.05 (0.35)
AR(1)	0.832***	0.078			0.309**	0.137		

Sursa: calcule proprii.

Valorile p între paranteze, ** înseamnă semnificație la 5% și *** arată semnificație la 1%.

Un instrument cheie al politicii monetare folosit pentru combaterea inflației este creșterea ratelor dobânzilor. Banca Națională a Cehiei (ČNB) a crescut proactiv ratele dobânzilor în perioada 2021-2022, anticipând creșterea inflației. Aceasta a ajutat la temperarea inflației într-o oarecare măsură. Banca Națională a României (BNR) a adoptat o abordare mai precaută, menținând ratele dobânzilor mai mici pentru o perioadă mai lungă comparativ cu Cehia. Această decizie a avut ca scop susținerea redresării economice după pandemie. Prin compararea celor două abordări, se poate observa potențialul efect al creșterilor ratelor dobânzilor asupra inflației. Deși inflația a crescut din cauza factorilor globali, abordarea proactivă a Cehiei cu privire la ratele dobânzilor ar fi putut contribui la moderarea creșterii mai mult decât dacă această strategie nu s-ar fi implementat.

Se pare că strategia ČNB este mai eficientă în reducerea inflației. În ultimul trimestru al anului 2021 și în primele două trimestre ale anului 2022, s-a observat o creștere mare a ratei dobânzilor. Pentru a verifica această ipoteză, conform căreia strategia ČNB a fost mai potrivită pentru reducerea inflației comparativ cu cea din România, se folosește o abordare bazată pe estimatorul diferenței-în-diferențe pentru perioada 2011: T1-2024: T2, utilizând date panel.

Testul de tendințe paralele (perioada pre-tratament) este aplicat sub ipoteza nulă că tendințele liniare sunt paralele. Testul de cauzalitate Granger presupune, sub ipoteza nulă, că nu există niciun efect în anticiparea tratamentului.

Înainte de implementarea strategiei ČNB, ambele țări au urmat o tendință paralelă, așa cum sugerează Tabelul 6. Ipoteza de absență a schimbării de comportament înainte de tratament nu este respinsă la un nivel de semnificație de 5%. Aceste constatări susțin validitatea estimării ATET („efectul mediu al tratamentului asupra celor tratați”).

Tabelul 6. Rezultatele abordării bazate pe estimatorul diferență-în-diferențe

ATET Strategia (1 vs 0)	Coeficient	Eroarea standard robustă	Valoarea p	Testul pentru trenduri paralele (stat. și valoarea p)	Testul pentru verificarea cauzalității Granger (stat. și valoarea p)
Inflația	-0.302	0.039	<0.01	0.53 (0.47)	0.25 (0.81)
Inflația așteptată	-0.972	0.489	<0.01	0.45 (0.51)	0.18 (0.89)
Inflația neanticipată	0.760	2.280	0.739	0.64 (0.33)	0.23 (0.82)

Sursa: calcule proprii.

Rezultatele indică o scădere a inflației în Cehia cu 0,302 puncte procentuale comparativ cu situația în care strategia bazată pe creșterea bruscă a ratelor dobânzilor nu ar fi fost implementată. Mai mult, inflația așteptată scade mai mult, cu 0,972 puncte procentuale, comparativ cu cazul în care rata dobânzii nu ar fi crescut brusc. Pe de altă parte, această strategie a determinat o inflație neașteptată mai mare, dar această creștere nu este semnificativă din punct de vedere statistic. Aceste constatări empirice sugerează că creșterea proactivă a ratelor dobânzilor realizată de ČNB a contribuit la reducerea inflației așteptate, dar fără control asupra inflației neașteptate.

O inflație mai scăzută și stabilă creează un mediu economic mai predictibil, ceea ce poate îmbunătăți încrederea mediului de afaceri în economie și poate duce la decizii de investiție mai bune. O inflație mai scăzută poate crea premisele pentru dobânzi mai mici în viitor. Aceasta poate stimula activitatea economică, investițiile și poate duce, în cele din urmă, la o economie cu o stabilitate mai mare. Cu toate acestea, creșterea ratelor dobânzilor poate avea și dezavantaje. În primul rând, ratele dobânzilor mai mari pot descuraja împrumuturile și investițiile, încetinind potențial creșterea economică. În al doilea rând, întreprinderile pot ezita să facă noi angajări dacă economia slăbește din cauza creșterii ratelor dobânzilor.

5. Concluzii

Furnizarea de previziuni pentru rata inflației este o un demers complex. Modelele economice structurale și raționamentul economic de bază sugerează că inflația ar trebui să fie predictibilă folosind diverși predictorii. Acești indicatori includ măsuri ale activității economice interne și internaționale, prețurile la import sau cursurile de schimb, măsuri ale costurilor, cum ar fi creșterea salariilor și prețul petrolului. Cu toate acestea, indicele sentimentului ca măsură a percepției experților asupra inflației viitoare este neglijat în toate aceste studii, dar această abordare ar putea îmbunătăți acuratețea previziunilor inflației. Acest studiu explorează capacitatea analizei sentimentului de a furniza indici pentru modele Bayesiene neparametrice care pot îmbunătăți acuratețea previziunilor. Rezultatele arată că modelele de regresie liniară Bayesiană oferă predicții mai bune ale inflației decât modelul GRNN pe orizontul 2023: T1-2023: T4. Previziunile pentru inflația din Cehia au fost mai bune decât previziunile pentru România, iar strategia de control al inflației aplicată de banca centrală a Cehiei a redus mai mult inflația. De fapt, inflația așteptată a fost redusă prin creșterea ratei dobânzilor, în timp ce această strategie nu a avut un efect semnificativ asupra inflației neașteptate.

Pornind de la aceste rezultate empirice, se pot propune politici de control al inflației. În primul rând, analiza sentimentului din rapoartele băncilor centrale ar putea fi integrată în modelele de previziune a inflației. Aceasta se poate realiza prin dezvoltarea de instrumente de analiză a sentimentului pentru a analiza tonul și conținutul rapoartelor băncilor centrale. În al doilea rând, băncile centrale ar trebui să fie proactive în ajustarea ratelor dobânzilor pentru a controla inflația. Băncile naționale ar trebui să monitorizeze îndeaproape tendințele inflației și să fie pregătite să ajusteze rapid ratele dobânzilor. Comunicarea transparentă din partea băncilor centrale cu privire la așteptările privind inflația și la deciziile de politică monetară este crucială. În al treilea rând, factorii de decizie politică și firmele ar trebui să acorde prioritate previziunilor inflației pe termen scurt pentru a lua decizii eficiente. Resurse suplimentare sunt necesare pentru dezvoltarea și rafinarea modelelor de prognozare pe termen scurt. În al patrulea rând, factorii de decizie politică și băncile centrale ar trebui să își monitorizeze și să își adapteze continuu strategiile în funcție de condițiile economice în evoluție. Factorii de decizie politică și băncile centrale ar trebui să evalueze periodic eficacitatea strategiilor de control al inflației. Războiul din Ucraina a avut un impact semnificativ asupra dinamicii inflației, arătând necesitatea flexibilității. Aceasta sugerează că ar trebui să fie pregătiți să își ajusteze politicile în funcție de circumstanțele în schimbare. În al cincilea rând, colaborarea dintre băncile centrale din Europa de Est poate fi benefică pentru schimbul de bune practici și coordonarea eforturilor de control al inflației. Abordarea problemelor structurale fundamentale din economie, cum ar fi blocajele din lanțul de aprovizionare și dependența energetică, poate contribui la controlul inflației pe termen lung. Prin implementarea acestor propuneri de politici, țările din Europa de Est își pot îmbunătăți capacitatea de a gestiona inflația și de a gestiona eficient provocările economice actuale.

Această cercetare prezintă câteva limitări, cum ar fi includerea a unui număr mic de predictorii ai inflației, utilizarea unui număr limitat de metode de prognoză și a unui număr mic de țări în analiză. Prin urmare, într-un studiu viitor, vor fi luați în considerare mai mulți predictorii ai inflației prin adăugarea cursului de schimb, a ratei șomajului etc. Alte metode de prognoză vor fi luate în considerare, cum ar fi modelele neliniare. Eșantionul de țări ar putea fi extins la mai multe țări din Europa de Est, cum ar fi Ungaria, Polonia și Slovacia.

Bibliografie

- Almosova, A., & Andresen, N. (2023). Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42(2), 240–259. <https://doi.org/10.1002/for.2901>
- Babb, N. R., & Detmeister, A. K. (2017). Nonlinearities in the Phillips Curve for the United States: Evidence Using Metropolitan Data. *Finance and Economics Discussion Series*, 2017(070). <https://doi.org/10.17016/feds.2017.070>
- Barkan, O., Benchimol, J., Caspi, I., Cohen, E., Hammer, A., & Koenigstein, N. (2023). Forecasting CPI inflation components with Hierarchical Recurrent Neural Networks. *International Journal of Forecasting*, 39(3), 1145–1162. <https://doi.org/10.1016/j.ijforecast.2022.04.009>
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Cardani, R., Croitorov, O., Giovannini, M., Pfeiffer, P., Ratto, M., & Vogel, L. (2022). The euro area's pandemic recession: A DSGE-based interpretation. *Journal of Economic Dynamics and Control*, 143. <https://doi.org/10.1016/j.jedc.2022.104512>
- Choudhary, M. A., & Haider, A. (2012). Neural network models for inflation forecasting: an appraisal. *Applied Economics*, 44(20), 2631-2635.
- Cimadomo, J., Giannone, D., Lenza, M., Monti, F., & Sokol, A. (2022). Nowcasting with large Bayesian vector autoregressions. *Journal of Econometrics*, 231(2), 500-519.
- Clark, T. E., Huber, F., Koop, G., & Marcellino, M. (2022). Forecasting US Inflation Using Bayesian Nonparametric Models. <http://arxiv.org/abs/2202.13793>
- Dotsey, M., Fujita, S., & Stark, T. (2018). Do Phillips Curves Conditionally Help to Forecast Inflation? *
- Hak Kim, H., Swanson, N. R., Corradi, V., Hendry, D., Koop, G., Landon-Lane, J., Li, F., & Tkacz, G. (2008). Mining Big Data Using Parsimonious Factor, Machine Learning, Variable Selection and Shrinkage Methods. Kim and Swanson.
- Hubrich, K. (n.d.). Standard-Nutzungsbedingungen. <http://www.ecb>.
- Joseph, A., Potjagailo, G., Kalamara, E., Chakraborty, C., & Kapetanios, G. (2022). Staff Working Paper No. 915 Forecasting UK inflation bottom up. www.bankofengland.co.uk/working-paper/staff-working-papers
- Karabatsos, G. (2018). Marginal maximum likelihood estimation methods for the tuning parameters of ridge, power ridge, and generalized ridge regression. *Communications in Statistics-Simulation and Computation*, 47(6), 1632-1651.
- Kim, D. H., & Lin, S. C. (2023). Income inequality, inflation and financial development. *Journal of Empirical Finance*, 72, 468–487. <https://doi.org/10.1016/j.jempfin.2023.04.008>
- Leung, M. T., Chen, A. S., & Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, 27(11-12), 1093-1110.
- Markus Jochmann. (2014). Modeling U.S. Inflation Dynamics: A Bayesian Nonparametric Approach. *Econometric Reviews*, 34(5), 537–558.
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, Á., & Zilberman, E. (2021). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business and Economic Statistics*, 39(1), 98–119. <https://doi.org/10.1080/07350015.2019.1637745>

Moshiri, S., & Cameron, N. (2000). Neural network versus econometric models in forecasting inflation. *Journal of forecasting*, 19(3), 201-217.

Simionescu, M. (2022). Econometrics of sentiments- sentometrics and machine learning: The improvement of inflation predictions in Romania using sentiment analysis. *Technological Forecasting and Social Change*, 182, 121867. <https://doi.org/10.1016/j.techfore.2022.121867>

Stock, J. H., Watson, M. W., Bauer, M., Bjørnland, H., Chodorow-Reich, G., Kilian, L., Plagborg-Møller, M., Ramey, V., & Anders, L. (2016). Factor Models and Structural Vector Autoregressions in Macroeconomics. <https://research.stlouisfed.org/econ/mccracken/fred-databases/>

Tierney, H. L. R. (2019). Forecasting with the Nonparametric Exclusion-from-Core Inflation Persistence Model Using Real-Time Data. *International Advances in Economic Research*, 25(1), 39–63. <https://doi.org/10.1007/s11294-019-09726-7>