

RAPORT

ETAPA 2 - decembrie 2023

Titlu Proiect: Soluții informatice pentru analiza impactului rețelelor de social media asupra instrumentelor investiționale cu grad ridicat de risc: cryptomonede și bursă

Domeniul științific: Științe economice

Membri:

**prof.univ.dr. Adela Bâra,
drd. Costin Băroiu**



În cadrul acestei etape, am diseminat rezultatele cercetării în următoarele lucrări:

- 1) Bâra, A., Oprea, S.V. & Băroiu, A.C. *Forecasting the Spot Market Electricity Price with a Long Short-Term Memory Model Architecture in a Disruptive Economic and Geopolitical Context*. Int J Comput Intell Syst 16, 130 (2023). <https://doi.org/10.1007/s44196-023-00309-3>
- 2) *A Descriptive – Predictive – Prescriptive Framework for the Social Media – Cryptocurrency Relationship*, Alexandru – Costin Băroiu și Adela Bâra. Articolul este în curs de pregătire și va fi transmis pentru evaluare.

1. În lucrarea *Forecasting the Spot Market Electricity Price with a Long Short-Term Memory Model Architecture in a Disruptive Economic and Geopolitical Context*, ne propunem să efectuăm o predicție pe termen scurt a prețului energiei electrice (EPF) folosind o rețea neurală recurentă (RNN), mai precis Long Short Term Memory (LSTM), utilizând un algoritm care selectează variabilele și optimizează hiperparametrii. Rezultatele sunt comparate cu unul dintre algoritmii de învățare automată de top, și anume eXtreme Gradient Boosting (XGB). Spre deosebire de alte soluții EPF, în acest articol, ne concentrăm pe intervalul dinainte și după pandemie și conflictul din Ucraina. De asemenea, spre deosebire de lucrările anterioare care au abordat în principal piețele de electricitate pe ziua următoare (Day-Ahead Market) din Germania, Austria, Australia, Spania și țările nordice, în acest articol punem accent pe EPF pentru una dintre țările din Europa de Est - România, ale cărei reguli de piață se aliniază îndeaproape cu regulile pieței de electricitate DAM a Uniunii Europene. Contribuția acestui studiu constă în crearea unui set de date care acoperă perioada din ianuarie 2019 până în august 2022 și furnizarea unui algoritm pentru a identifica cea mai bună arhitectură LSTM cu mai multe straturi pentru a face față unei provocări EPF pe termen scurt. Algoritmul propus identifică variabilele cele mai relevante folosind un prag de corelație și efectuează o combinație a trei parametri - dimensiunea stratului ascuns, stratul dropout și rata de învățare generând cele mai bune rezultate cu privire la EPF.

Introducerea stabilește contextul studiului, subliniind impactul evenimentelor recente, cum ar fi pandemia COVID-19 și conflictul din Ucraina, asupra piețelor de energie electrică. Se prezintă importanța vitală a predicției prețurilor pe piața spot a electricității pentru actorii de pe piață și economie în general. Cercetarea își propune să dezvolte și să testeze un model LSTM avansat pentru a îmbunătăți predicția prețurilor la energia electrică în acest context volatil.

Analiza literaturii de specialitate oferă o prezentare amănunțită a literaturii existente în domeniul predicției prețurilor de energie electrică. Se pune accent pe evoluția metodelor de predicție, de la modele statistice la tehnici avansate de învățare automată, cu un focus special pe modelul LSTM. Se compară acest model cu alte abordări, cum ar fi Convolution Neural Network (CNN) și Suport Vector Machine (SVM), evidențiind avantajele și limitările fiecăruia.

Secțiunea 3 prezintă analiza datelor de intrare. Autorii descriu procesul de colectare, pre-procesare și analiză a datelor. Setul de date include informații despre prețurile istorice ale energiei electrice, cantitățile tranzacționate și alte variabile economice relevante, precum condiții meteorologice și indicatori economici. Se detaliază metodele de normalizare a datelor și se prezintă o matrice de corelație pentru a identifica relațiile dintre diferite variabile.


Pentru studiul efectuat pentru perioada ianuarie 2019 - august 2022, datele de intrare au fost extrase din mai multe surse:

1. **Operatorul pieței de energie electrică din România (OPCOM):** S-au obținut prețurile orare la electricitate și cantitățile tranzacționate. Aceste date reflectă valorile specifice pieței românești de electricitate, oferind o perspectivă asupra fluctuațiilor prețurilor și a volumelor tranzacționate pe piața spot.
2. **Bursa Română de Mărfuri:** S-au extras prețurile la gaze pe piața pentru ziua următoare (DAM) și cantitățile asociate. Prețurile la gaze sunt relevante pentru studiu deoarece influențează și sunt influențate de prețurile electricității, având în vedere interdependența dintre piețele de energie.
3. **Institutul Național de Statistică:** De la această instituție au fost colectat date despre rata inflației în România. De asemenea, au mai fost utilizate în analize rata inflației în Europa și prețul petrolului. Aceste variabile macroeconomice sunt importante pentru analiza propusă, deoarece rata inflației și prețurile la materii prime precum petrolul pot avea un impact semnificativ asupra pieței energiei.

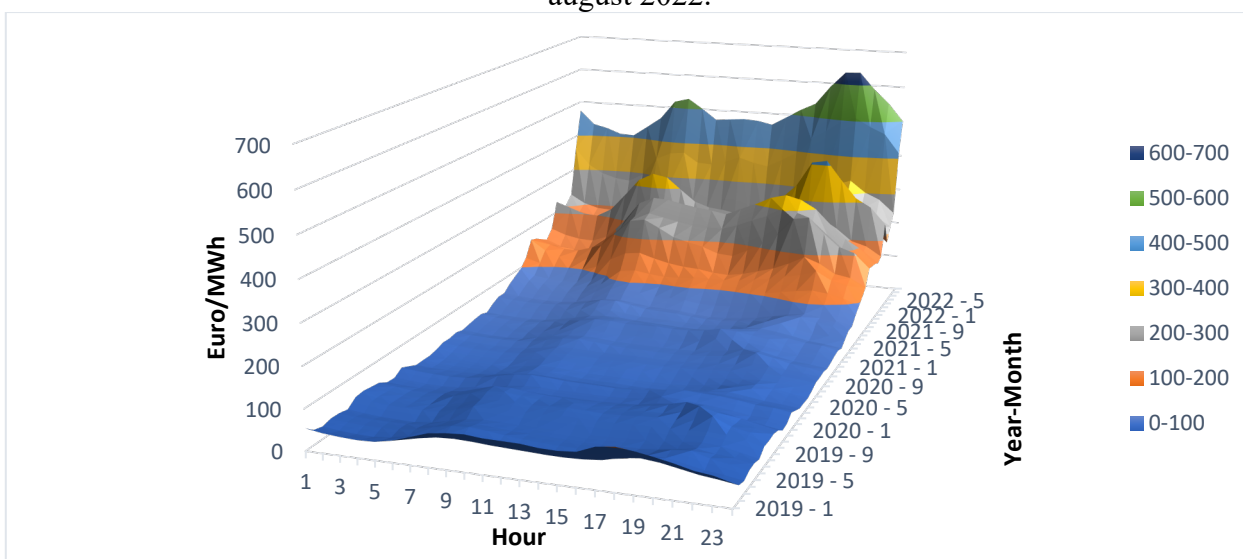
Analiza acestor date oferă o imagine complexă a pieței energiei, luând în considerare atât factorii specifici sectorului energetic (prețurile la electricitate și gaze, cantitățile tranzacționate), cât și factorii

macroeconomici (inflația, prețurile la petrol), toți acești factori având potențialul de a influența prețurile la electricitate. Această abordare multidimensională este crucială pentru a înțelege dinamica pieței și pentru a dezvolta modele predictive precise.


Au fost realizate următoarele grafice:



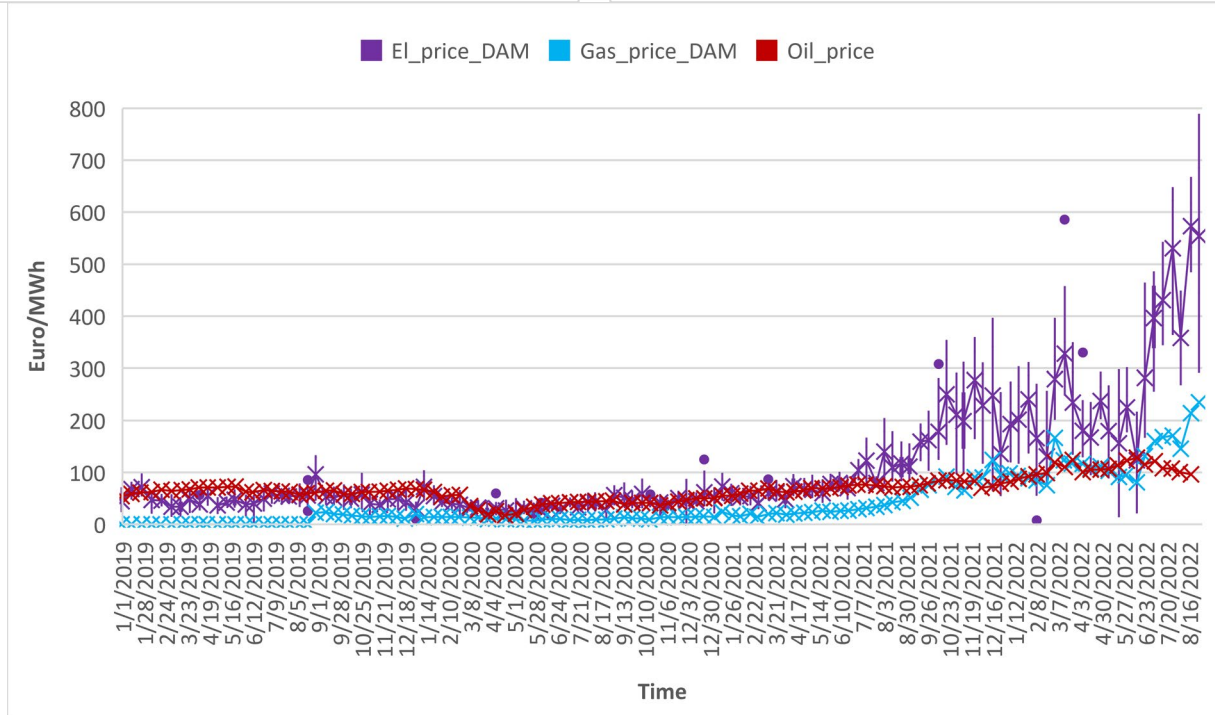
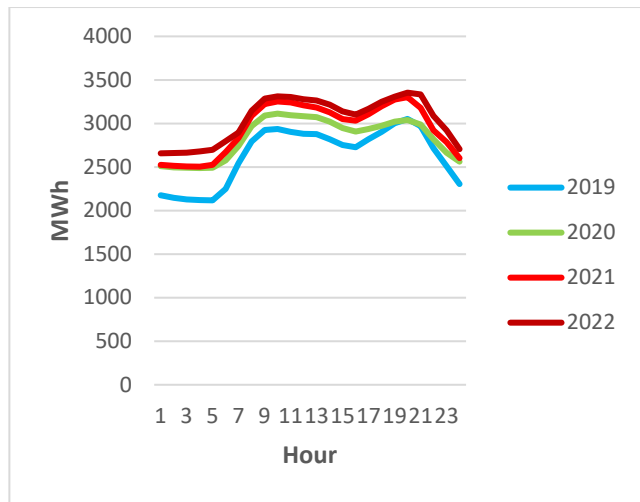

Abaterea standard a prețului electricității pe piața pentru ziua următoare (DAM) din ianuarie 2019 până în august 2022.



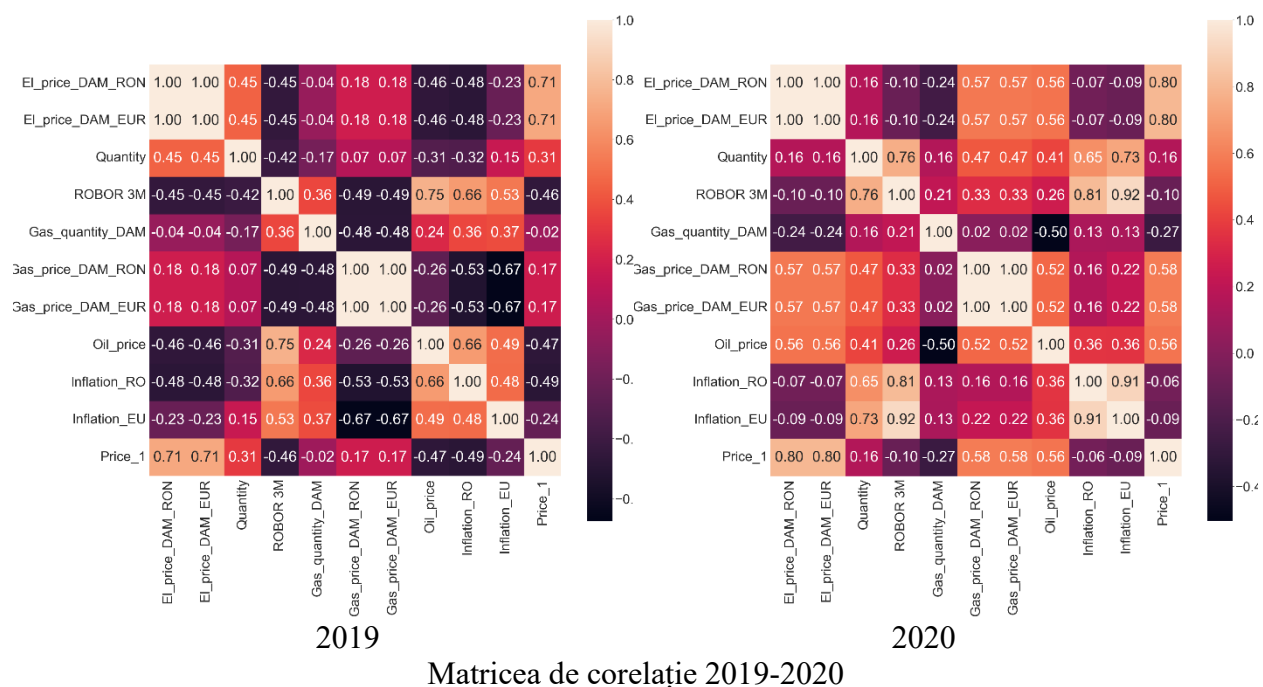
Prețurile medii pe piața pentru ziua următoare (DAM) din ianuarie 2019 până în august 2022.



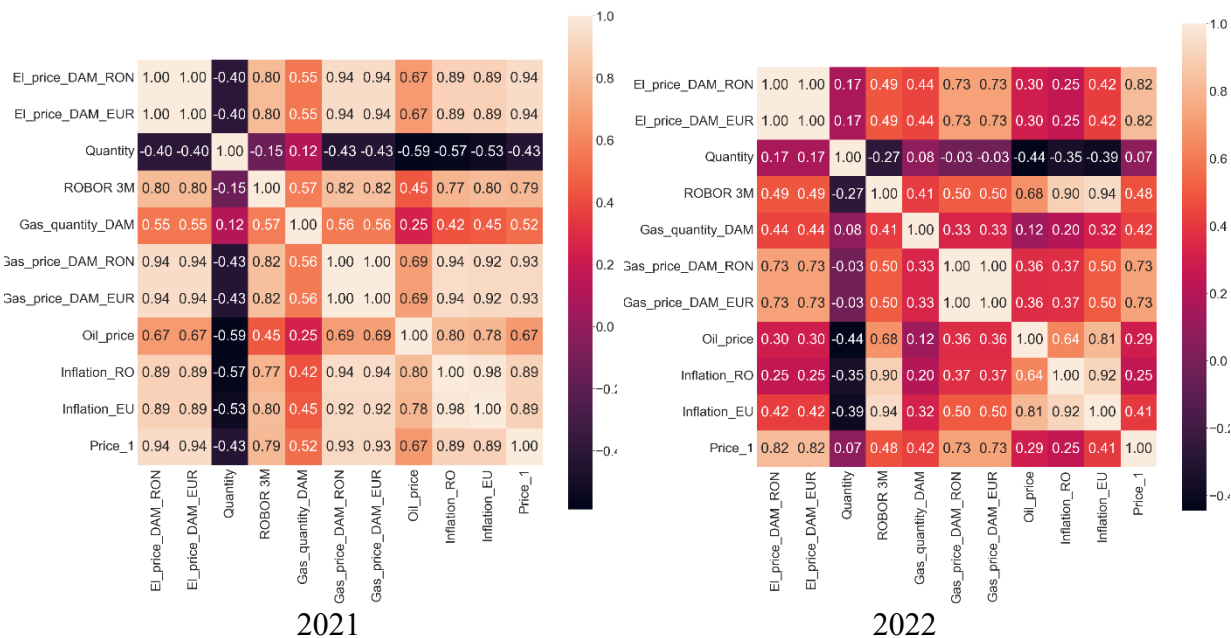
Prețul mediu orar al electricității și volumul tranzacționat din 2019 până în 2022.



Evoluția prețurilor la electricitate, gaz și petrol între ianuarie 2019 și august 2022.



Matricea de corelație 2019-2020



Matricea de corelație 2021-2022

În secțiunea Metodologie, se detaliază construirea și optimizarea modelului LSTM. Se abordează structura modelului, selecția hiperparametrilor, tehnici de validare încrucișată și particularități specifice modelului, precum capacitatea de a reține informații pe termen lung.

În secțiunea Rezultate, se prezintă rezultatele obținute de modelul LSTM, comparându-le cu performanțele altor metode de predicție. Se analizează precizia predicțiilor, stabilitatea modelului în diferite condiții de piață și adaptabilitatea acestuia la evenimente neprevăzute.

În secțiunea Discuții, se estimează cum rezultatele obținute răspund întrebării din introducere (research question). Se analizează impactul contextului economic și geopolitic asupra prețurilor la electricitate și eficacitatea modelului în predicția acestor prețuri. De asemenea, se discută limitările modelului și potențialele sale vulnerabilități.

Secțiunea Concluzii de încheiere rezumă principalele constatări ale studiului, subliniind importanța acestor descoperiri pentru sectorul energetic. Se propun direcții viitoare de cercetare, inclusiv explorarea altor modele sau combinații de modele pentru a îmbunătăți predicțiile.

Anexa și referințele completează documentul, oferind detalii suplimentare și surse de referință pentru cercetare, permițând cititorilor să aprofundeze aspectele abordate.

Prin această analiză detaliată, se oferă o perspectivă aprofundată asupra abordării și rezultatelor cercetării în domeniul predicției prețurilor pe piața spot a electricității, evidențiind complexitatea și relevanța acestui domeniu într-un mediu economic

2. În cadrul lucrării *A Descriptive – Predictive – Prescriptive Framework for the Social Media – Cryptocurrency Relationship* am introdus cadrul Descriptiv – Predictiv – Prescriptiv pentru relația dintre Social Media și Criptomonedă. Creșterea popularității criptomonedelor, în special a Bitcoin, a schimbat fundamental sistemul financiar. Cu toate acestea, instabilitatea criptomonedelor prezintă provocări semnificative pentru investitori și reglementatori, datorită naturii lor speculative și susceptibilității la fluctuațiile pieței, adesea amplificate prin social media.

Piața criptomonedelor, spre deosebire de piețele tradiționale, nu are indicatori stabiliți pentru orientarea investițiilor. Aceasta generează provocări în prezicerea traiectoriei investițiilor. Caracteristicile unice ale criptomonedelor în finanțe, cum ar fi natura lor descentralizată și lipsa suportului fizic, adaugă la complexitatea domeniului. Emergența platformelor de social media a introdus o nouă dimensiune în discuția despre criptomonedă. Relația între discursul de pe social media și piețele crypto necesită un instrument analitic cuprinzător. Uneltele convenționale de analiză financiară sunt adesea insuficiente pentru a înțelege complexitățile pieței. Studiul propune un cadru Descriptiv-Predictiv-Prescriptiv (DPP) pentru a integra știința datelor cu analiza socio-economică, având scopul de a dezvolta un instrument care nu numai că descrie și prognozează tendințele de piață, dar oferă și recomandări practice.

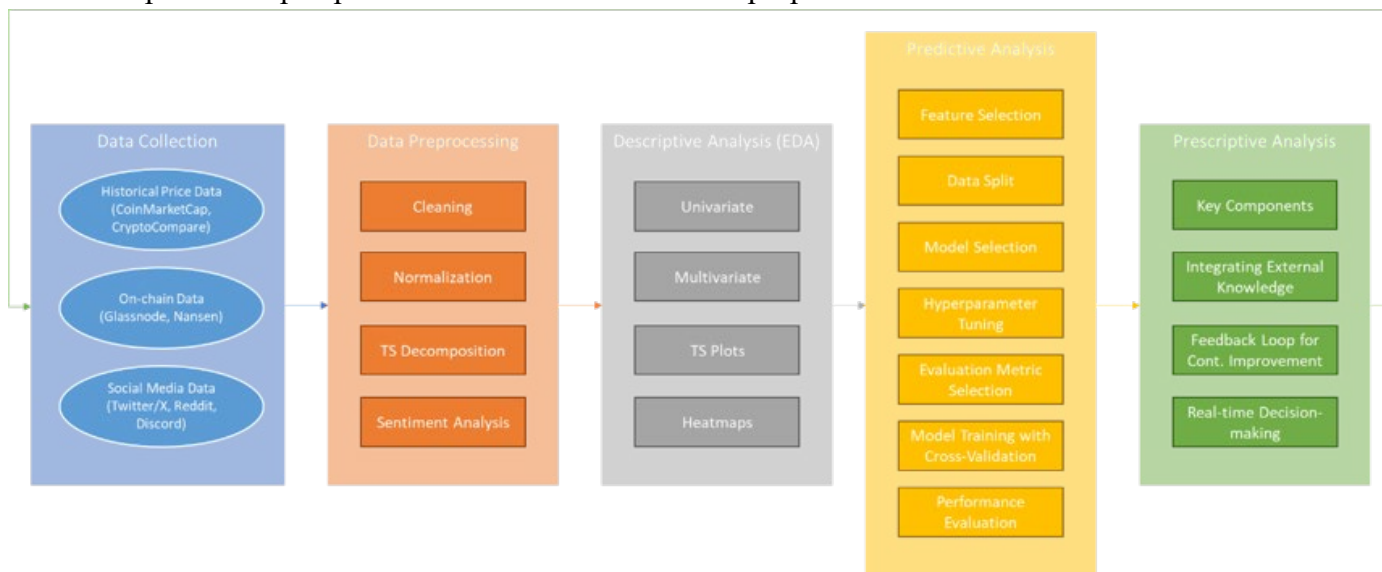
Interacțiunea dintre dinamica rețelelor sociale și piețele de criptomonedă extrem de fluctuante creează o relație simbiotică sofisticată, influențând economia digitală. Cadru DPP analizează eficient complexitatea Bitcoin și a altor criptomonedă. Prin combinarea științei datelor avansate cu perspective socio-economice,

studiul depășește analiza simplă și devine un instrument inovator pentru clarificare, predicție și consiliere, cu potențialul de a revoluționa luarea deciziilor în domeniu. Articolul contribuie semnificativ la analiza predictivă și oferă îndrumări valoroase pentru navigarea investițiilor în Bitcoin cu previziune și încredere. Influența globală și structura descentralizată a rețelelor sociale și criptomonedelor adaugă complexitate suplimentară. Piața crypto poate fi influențată de evenimente internaționale, precum schimbările de reglementare și inovații tehnologice. Lucrarea detaliază cadrul propus și viitoarele direcții de studiu.

Cadrul DPP

Dezvoltarea unui cadru descriptiv-predictiv-prescriptiv pentru relația social media-criptomonedă are o importanță academică și industrială substanțială. Din punct de vedere academic, acest cadru oferă o modalitate structurată de a înțelege și modela o sarcină complicată, cu perspective de cercetare și dezvoltare suplimentare. Acest lucru se adaugă la corpul de cunoștințe și stabilește bazele cercetărilor viitoare. Dezvoltarea cadrului a fost motivată de proeminența crescândă a criptomonedelor în ecosistemul financiar și de influența notabilă a rețelelor sociale asupra percepției publice în legătură cu aceste active digitale. Recunoașterea limitărilor parametrilor financiari convenționali în înțelegerea dinamicii pieței criptomonedelor a devenit progresiv evidentă. Natura complexă și cu mai multe fațete a industriei crypto, care a fost îmbunătățită de apariția tokenomiei și a implicării globale pe scară largă, a cerut o abordare cuprinzătoare și atotcuprinzătoare. Scopul acestui cadru este dublu, explorarea științifică și implicațiile practice. Scopul acestui studiu este de a stabili o abordare sistematică pentru ca cercetătorii să navigheze în mod eficient pe terenul complicat al pieței crypto. Cadrul urmărește să stabilească o procedură sistematică, cu o serie de pași secvențiali, pentru a aduce uniformitate investigației acestei discipline emergente și a oferi un model care poate fi reprodus în eforturile de cercetare ulterioare. Pe lângă aplicarea sa în cercetarea academică, acest cadru a fost conceput ținând cont de analiștii financiari, persoanele interesate de criptomonede și potențialii investitori. Obiectivul principal al designului său este de a oferi perspective practice și aplicabile, facilitând astfel luarea deciziilor bine informate într-un mediu de piață adesea imprevizibil.

Cadrul facilitează legătura dintre datele brute și analiza perspicace prin încorporarea instrumentelor de analiză a datelor. Scopul acestui instrument este de a acționa ca un mediu prin care cantități mari de date neorganizate din diverse origini sunt convertite într-un format structurat, stabilind astfel fundația pentru o analiză cuprinzătoare ulterioară. Următoarele secțiuni vor oferi o analiză mai detaliată a fiecărui pilon și etapă a cadrului, explicând metodologiile utilizate, raționamentul din spatele fiecărei alegeri și consecințele constatărilor obținute. Stabilirea unui cadru matematic precis pentru descrierea fiecărei componente permite obținerea coerenței, repetabilității și clarității în procesarea și analiza diferitelor seturi de date. Scopul acestui cadru este de a gestiona eficient complexitățile datelor, oferind o abordare structurată pentru a converti informațiile neprocesate în informații strategice valoroase. Pentru a vizualiza mai bine Cadrul DPP, figura următoare prezintă o perspectivă la nivel înalt a abordării propuse.

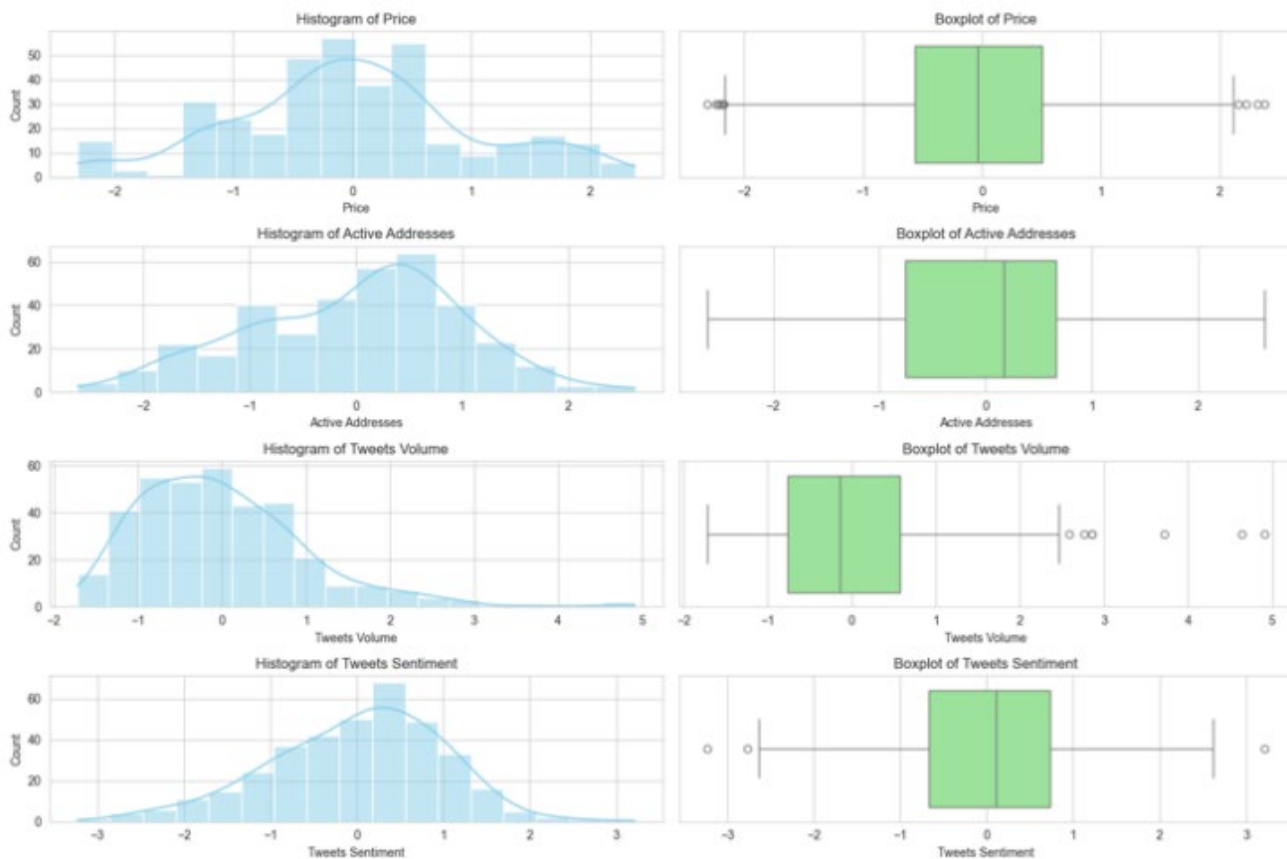


Cadrul descriptiv - predictiv - prescriptiv pentru relația Social Media - Criptomonede

Exemplu Experimental

Pentru a demonstra competența cadrului DPP, a fost efectuat un exemplu experimental pentru această lucrare. A fost construit un set de date de 365 de observații zilnice, de la 1 iulie 2021 până la 30 iunie 2022, compus din prețul Bitcoin, date în lanț și date Twitter. Setul de date a fost selectat doar pentru a oferi un exemplu de îmbunătățiri așteptate ale cadrului DPP. Datele au fost colectate de la CoinMarketCap pentru

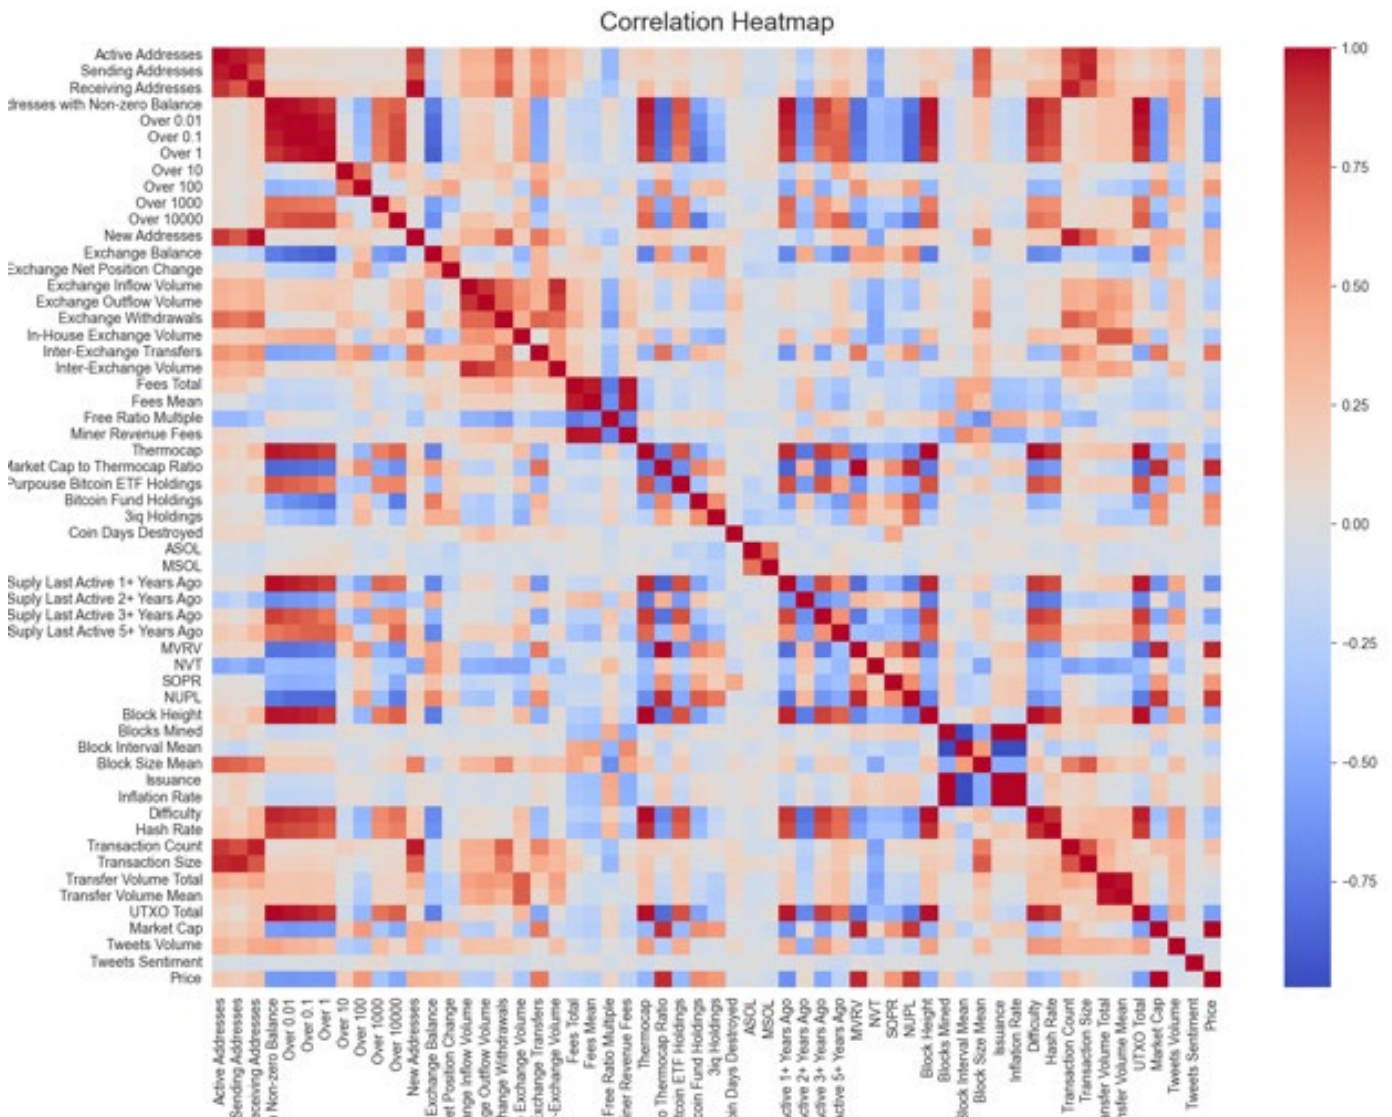
informații despre prețul Bitcoin, Glassnode pentru datele în lanț și X (ex-Twitter) pentru datele de pe rețelele sociale. Sentimentul tweet-urilor a fost extras folosind un model de tip regresie logistică cu un scor f1 raportat de 0,79 pe un set de date public Twitter de la Kaggle. Toate datele și codul folosit pentru a efectua experimentul sunt găzduite într-un repository public la: https://github.com/Emposes/DPP_Framework. După ce setul de date a fost construit, au fost efectuate preprocesarea și analiza datelor. Setul de date este curat, fără date lipsă. Toate datele sunt numerice și au fost normalizate folosind metoda z-score. Pentru analiza univariată, s-au folosit diverse metode, cum ar fi reprezentarea grafică a distribuției și diagramele boxplot pentru variabilele extreme. Un exemplu este dat în figura următoare.



Exemplu de analiză univariată

Pentru exemplul din figura anterioară, variabilele investigate, anume Prețul, Adresele active, Volumul Tweets și Sentimentul Tweet-ului, au fost reprezentate grafic prin histograme și boxplot pentru a obține informații despre distribuție lor și măsurile de tendință centrală. Histograma care reprezintă distribuția prețului prezintă un model predominant normal, cu o asimetrie minoră spre stânga sugerând o grupare de valori sub medie. Boxplot-ul demonstrează o mediană care este aproximativ aliniată cu marcajul zero, indicând o tendință centrală. Marginile sunt simetrice, sugerând o distribuție uniformă a datelor în jurul mediei. În plus, există multe valori aberante la nivelul superior, indicând prezența câtorva apariții cu prețuri mult mai mari.

Distribuția adreselor active, așa cum este descrisă de histogramă, prezintă caracteristicile unei distribuții aproape normale, cu o declinare minoră la dreapta. Boxplot-ul nu oferă informații cu privire la existența valorilor aberante. Cu toate acestea, afișează o mediană ceva mai mare decât zero, ceea ce sugerează că majoritatea punctelor sunt concentrate în jurul mediei, prezentând o distribuție simetrică pe ambele părți. Histograma care reprezintă volumul de tweet-uri prezintă o distribuție care este înclinată spre dreapta, indicând faptul că majoritatea datelor sunt grupate către valorile inferioare, în timp ce o proporție mai mică a datelor este răspândită către valorile mai mari. Boxplot-ul oferă suport pentru această afirmație prin afișarea unei valori medii sub zero, precum și prezența unor valori aberante care sugerează cazuri sporadice de volume mari de tweet-uri. Reprezentarea sentimentului în tweet-uri este reprezentată de o histogramă care are o distribuție oblică la dreapta, indicând o frecvență mai mare a evaluărilor mai scăzute ale sentimentului. Boxplot-ul afișează o valoare mediană care este ușor pozitivă, iar existența unor valori aberante la ambele capete indică apariții rare de sentimente extreme în întregul set de date. În continuare, analiza multivariată a fost efectuată prin calcularea matricei de corelație și generarea unei hărți termice, prezentată în figura următoare.



Matricea de corelație

Studiul de corelație a fost efectuat pentru a investiga asocierile liniare dintre o gamă diversă de factori relevanți pentru dinamica criptomonedelor. Heatmap-ul reprezintă vizual diferitele grade de corelație observate între perechi distincte de variabile.

Relația dintre sentimentul pieței și activitatea din social media sugerează o asociere favorabilă între volumul de tweet-uri și diverși indici ai activității pieței, inclusiv adresele active, adresele de trimitere și adresele de primire. Acest lucru implică faptul că poate exista o corelație între implicarea mai mare în rețelele sociale și activitatea tranzacțională sporită pe platformă. Măsurile referitoare la mișcarea activelor între burse, cum ar fi volumul de intrare în schimb și volumul de ieșire la schimb, au asocieri semnificative cu capitalizarea pieței și prețul, sugerând impactul potențial al dinamicii schimbului asupra evaluării pieței.

Există o asociere notabilă între variabile precum Bitcoin Fund Holdings și Purpose Bitcoin ETF Holdings și indicatorii de valoare de piață, cum ar fi Market Cap. Acest lucru sugerează că investițiile instituționale au o influență substanțială asupra capitalizării globale de piață. Prezența anumitor indicatori, cum ar fi Supply Last Active 1+ Year ago, care indică deținerea pe termen lung, demonstrează o asociere negativă cu diverși indicatori de volatilitate. Acest lucru sugerează că deținerea pe termen lung are un impact stabilizator asupra volatilității pieței.

Analiza efectuată a scos în evidență corelații demne de remarcat între prețul Bitcoin și alte elemente, evidențiind interrelațiile dintre acești factori și fluctuațiile de preț. Capitalizarea prezintă o corelație pozitivă puternică ($r = 0,999841$) cu prețul, ceea ce indică faptul că atunci când capitalizarea crește, prețul tinde să urmeze îndeaproape. Această relație este în conformitate cu așteptările, deoarece capitalizarea este influențată atât de preț, cât și de oferta circulantă. Valoarea MVRV (Valoarea de piață la valoarea realizată) prezintă o asociere pozitivă robustă ($r = 0,945733$), ceea ce implică faptul că ratele MVRV ridicate, care indică primele de piață, coincid frecvent cu mișcările în creștere ale prețurilor. Legătura dintre Market Cap și Thermocap Ratio și preț este foarte semnificativă ($r = 0,928591$), indicând o relație puternică pozitivă. Acest raport este folosit în mod

obișnuit pentru a detecta maximele și scăderile pieței, deoarece prezintă mișcări paralele cu prețul, indicând, prin urmare, cazuri de supra- sau subevaluare.

Profitul/pierderea nerealizată (NUPL) demonstrează o corelație pozitivă semnificativă ($r = 0,899086$), indicând o aliniere strânsă între amploarea profitului sau pierderii nerealizate de pe piață și fluctuațiile prețului. Constatările indică faptul că există o legătură pozitivă moderată ($r = 0,654808$ și $r = 0,570188$) între transferurile interbursiere și deținerile de fonduri Bitcoin, sugerând că o creștere a transferurilor de active și acumularea de fonduri poate fi legată de aprecierea Bitcoin. Valorile referitoare la activitățile din lanț, cum ar fi SOPR, activitatea de adrese (adrese active, adrese de primire) și adrese noi, prezintă corelații pozitive moderate până la scăzute (cu coeficienți de corelație variind de la 0,513680 la 0,238624). Aceste corelații sugerează o legătură între activitatea rețelei și preț, deși puterea acestei relații este mai slabă în comparație cu indicatorii financiari.

Analiza sentimentului tweet-urilor dezvăluie o corelație negativă semnificativ slabă ($r = -0,019029$), indicând că există o asociere minimă sau deloc liniară între sentimentul general exprimat pe rețelele sociale cu privire la Bitcoin și prețul acesteia. Analiza MSOL și Valorile Volumului de Transfer relevă corelații negative ușoare (variind de la $r = -0,098113$ la $r = -0,119308$). Aceste constatări sugerează că nu există o legătură liniară semnificativă din punct de vedere statistic între aceste valori ale volumului de aprovizionare și transfer și modificările prețurilor. Mai mulți factori au prezentat asocieri slabe sau neglijabile cu prețul.

Există unele elemente care prezintă corelații negative semnificative cu prețul, care pot fi de o importanță deosebită în înțelegerea dinamicii pieței. Este de remarcat faptul că există o corelație negativă semnificativă ($r = -0,655136$) între creșterea ofertei Last Active acum 1+ ani și preț. Aceasta implică faptul că păstrarea activelor pentru o perioadă mai lungă poate fi legată de prețuri mai mici. Această observație ar putea indica o reducere a lichidității pieței sau a presiunii de vânzare. Datele relevă o corelație negativă semnificativă ($r = -0,515925$) între numărul de adrese peste 10.000 și înălțimea blocului. În mod similar, se arată o corelație negativă substanțială ($r = -0,476777$) între etapele de creștere blockchain și scăderile de preț. Aceste constatări sugerează că pragurile specifice de concentrare a adreselor sau progresele semnificative în dezvoltarea blockchain-ului se pot alinia cu scăderile prețurilor criptomonedelor. Studiul Supply Dynamics arată că există o asociere negativă mare între variabilele Supply Last Active acum 3+ ani ($r = -0,532824$) și UTXO Total ($r = -0,573622$) cu prețul. Acest lucru indică faptul că, în perioadele de prețuri mai scăzute, există o prevalență mai mare a vârstei crescute a ofertei și a rezultatelor tranzacțiilor nechețuite.

Amploarea și orientarea acestor corelații oferă informații valoroase care pot fi de interes pentru investitori, comercianți și cercetători care caută să înțeleagă factorii determinanți care influențează fluctuațiile prețurilor pe piața Bitcoin. După pasul EDA, a fost antrenat un model de referință de regresie logistică. Modelul de referință a folosit doar date despre preț, prezicând prețul de ziua următoare și folosind doar prețul de astăzi. RMSE și MAE au fost utilizate ca metrici. Performanța modelului de bază este următoarea: RMSE, 1352,25 și MAE, 1011,78. Valoarea RMSE reprezintă abaterea standard a reziduurilor, care sunt erorile de predicție. O valoare RMSE mai mică este de preferat, deoarece indică o potrivire mai apropiată de date. În contextul modelului de bază, acesta oferă un punct de plecare pentru rafinarea modelului. Spre deosebire de RMSE, MAE oferă un scor liniar care face media diferențelor absolute dintre valorile prezise și cele reale. Acest lucru oferă o interpretare directă a cât de mult, în medie, se abate predicțiile de la prețurile reale. Performanța obținută prin ambele abordări este prezentată în tabelul următor.

METRICA PERFORMANȚEI - BASELINE VS DPP

Abordare	RMSE	MAE
De bază	1352,25	1011,78
DPP	1305,73	965,3

Pentru acest exemplu, a fost folosit un model simplu pentru a îmbunătăți rezultatul de bază. Deși se recomandă un model LSTM, în scopul acestui exemplu a fost selectată regresia Ridge, deoarece reglarea hiperparametrului poate fi efectuată pe parametrul „alfa” prin intermediul GridSearch, iar simplitatea acestui model poate demonstra mai bine eficiența DPP. Pragurile de corelație Pearson utilizate au variat între 0,95 și 0,4, cu un pas de 0,05. Performanța raportată a modelului îmbunătățit este următoarea: RMSE, 1305.73, și MAE, 965.30. Reducerea RMSE cu 46,52 unități indică o potrivire mai precisă la datele observate, sugerând că îmbunătățirile aduse modelului au fost eficiente în capturarea mai precisă a mișcărilor de preț. Scorul MAE este mai mic decât al modelului de bază cu 46,5 unități. Această îmbunătățire confirmă în continuare că amploarea medie a erorilor în predicțiile de preț a fost redusă, sporind astfel fiabilitatea modelului. Îmbunătățirile observate în RMSE și MAE ale modelului propus indică faptul că modificările și optimizările implementate variabilelor predictive și metodologiei algoritmice au dat un rezultat favorabil. Îmbunătățirile au avut ca rezultat un model care nu numai că prezintă un grad mai mare de conformitate cu datele istorice, dar și diminuează discrepanța medie în prognoze.

Acest lucru este de interes pentru cei care se bazează pe previziuni precise pentru a-și informa procesele de luare a deciziilor.

Pentru a continua exemplul și a oferi o perspectivă asupra modului în care ar putea fi aplicat Cadrul DPP, presupunem că o parte interesată are sarcina de a supraveghea un portofoliu de investiții, cu obiectivul de a maximiza randamentul activelor Bitcoin, atenuând în același timp expunerea la risc. Pe baza rezultatelor generate de modelul predictiv îmbunătățit, se estimează că valoarea unei anumite criptomonede va avea probabil o tendință ascendentă. Această proiecție se bazează în mare parte pe creșterea concomitentă observată a adreselor active.

Analiza prescriptivă se referă la procesul analitic care utilizează date și modele statistice pentru a oferi recomandări și îndrumări pentru luarea deciziilor, implementând un sistem de monitorizare. Scopul acestei evaluări a performanței este de a evalua succesul analizei prescriptive prin compararea rezultatelor reale cu rezultatele așteptate în timpul perioadei de execuție. Această evaluare își propune să perfecționeze procesele viitoare de luare a deciziilor pe baza constatărilor. În mod ideal, decizia de a modifica strategiile de investiții bazate pe modelul predictiv ar trebui să producă un ROI pozitiv, evaluând acuratețea proiecțiilor. În cazul în care piața se abate de la comportamentul anticipat, este important să se utilizeze măsuri de diminuare a riscurilor care au ca scop limitarea pierderilor potențiale. Pentru a ilustra mai bine cadrul DPP în acțiune, să luăm în considerare un scenariu ipotetic, prezentat în tabelul următor.

EXEMPLU DE ANALIZĂ PRESCRIPTIVĂ

Componenta de analiză prescriptivă	Detalii
Prognoza modelului predictiv	A prognozat o creștere cu 10% a prețului Bitcoin în următorul trimestru.
Rezultatele analizei descriptive	Prețul actual al Bitcoin: 30.000 USD Prețul estimat (trimestrul următor): 33.000 USD Indicele de sentiment al rețelelor sociale: +0,75 Volatilitatea curentă a pieței: ridicată
Alocarea investițiilor	Deținerea actuală de Bitcoin: 2 BTC (60.000 USD) Investiție suplimentară: 10% din valoarea portofoliului Achiziție nouă de Bitcoin: 0,2 BTC (6.000 USD)
Atenuarea riscurilor	Ordin Stop-Loss stabilit la 5% sub prețul curent al pieței (28.500 USD)
Analiza lichidității	Volumul mediu zilnic de tranzacționare: 350.000 BTC Lichiditate mare, lichidare ușoară
Strategia de diversificare	Corelație cu Aur: -0,6 Investiție în aur: 30% din investiția suplimentară
Planificare și execuție strategică	Nivelul de încredere al modelului: 85% Creștere a alocării investițiilor: 10%
Monitorizare și Evaluare a Performanței	Alocarea aurului pentru diversificare Bitcoin a atins 33.000 USD estimați până la sfârșitul trimestrului Aurul s-a apreciat cu 2%
Analiza rezultatelor	Valoarea deținerii Bitcoin la sfârșitul trimestrului: 72.600 USD Valoarea investiției în aur la sfârșitul trimestrului: 1.836 USD Valoarea totală a portofoliului la sfârșitul trimestrului: 74.436 USD ROI: 12,78%
Concluzie	Cadrul DPP a oferit o strategie de investiții de succes, care a generat un ROI pozitiv și gestionând eficient riscul prin diversificare și ordine stop-loss.

Acest exemplu demonstrează puterea cadrului DPP nu numai de a prezice tendințele pieței, ci și de a transforma aceste predicții în strategii de investiții acționabile care gestionează riscul și valorifică oportunitățile de pe piața criptomonedelor.

Pe scurt, integrarea analizei datelor și modelării predictive posedă capacitatea de a exercita o influență substanțială asupra procesului decizional pe piața Bitcoin. Studiile ulterioare ar trebui să prioritizeze îmbunătățirea acestor modele și să aprofundeze în conexiunile cauzale sugerate de corelațiile observate pentru a exploata pe deplin capacitățile de analiză predictivă din acest domeniu.

În concluzie, în domeniul dinamic al criptomonedelor și relația lor cu platformele de social media, cadrul prezentat în această lucrare oferă o metodologie sistematică și academică pentru descifrarea, înțelegerea și utilizarea acestor complexități. Acest studiu abordează în mod eficient disparitatea dintre abundența datelor nestructurate și utilizarea practică a informațiilor valoroase, oferind o abordare cuprinzătoare care cuprinde întregul proces, de la colectarea datelor până la luarea deciziilor prescriptive.

Semnificația încorporării sentimentului rețelelor sociale, a datelor istorice despre prețuri și a valorilor în lanț este de cea mai mare importanță într-o epocă în care opiniile online au potențialul de a influența rapid dinamica pieței. Adaptabilitatea, fiabilitatea și precizia cadrului sunt asigurate prin implementarea metodologiilor riguroase și prin utilizarea tehnicilor avansate de învățare automată și de învățare profundă. Cu toate acestea, există domenii în care cadrul DPP ar putea cunoaște îmbunătățiri, cum ar fi: adaptabilitate în timp real, colaborări interdisciplinare, considerații etice și de reglementare și integrare cu Blockchain, printre altele.

Apariția criptomonedelor a adus o instabilitate și un potențial de neegalat în domeniul financiar. Pentru a valorifica acest potențial, este necesar să se utilizeze instrumente avansate, metodologii și perspective. Cadrul DPP propus reprezintă un progres substanțial în acest aspect și este primul de acest gen, după cunoștințele noastre. Adaptabilitatea, metodologia riguroasă și natura cuprinzătoare a acestui instrument îl fac indispensabil pentru cercetători, investitori și decidenții politici. Comunitatea globală se află în pragul unei transformări tehnologice semnificative. Acest cadru conceptual servește drept fundație pentru valorificarea efectivă a gamei vaste de beneficii potențiale, recunoscând în același timp obstacolele care pot apărea.