

Dezvoltarea unui Framework descriptiv - predictiv - prescriptiv pentru relația social media - cryptomonedede

Doctorand Băroiu Alexandru - Costin

Prof. Dr. Adela Bâra

AOSR - 5 Iulie 2024 - Bucuresti

Introducere

- ▶ Denumire proiect: *“Soluții informatice pentru analiza impactului rețelelor de social media asupra instrumentelor investiționale cu grad ridicat de risc: cryptomonede și bursă”*
- ▶ Obiectivele programului de cercetare:
 - ▶ Studiul relației dintre Social Media și instrumente investitoriale
 - ▶ Dezvoltarea de modele de predictive pentru evoluția pretului activelor investitoriale
 - ▶ Dezvoltarea unui framework descriptiv-predictiv-prescriptiv pentru relația social media - cryptomonede
 - ▶ Îmbunătățirea framework-ului DPP cu ajutorul LLM-urilor

Diseminarea Rezultatelor

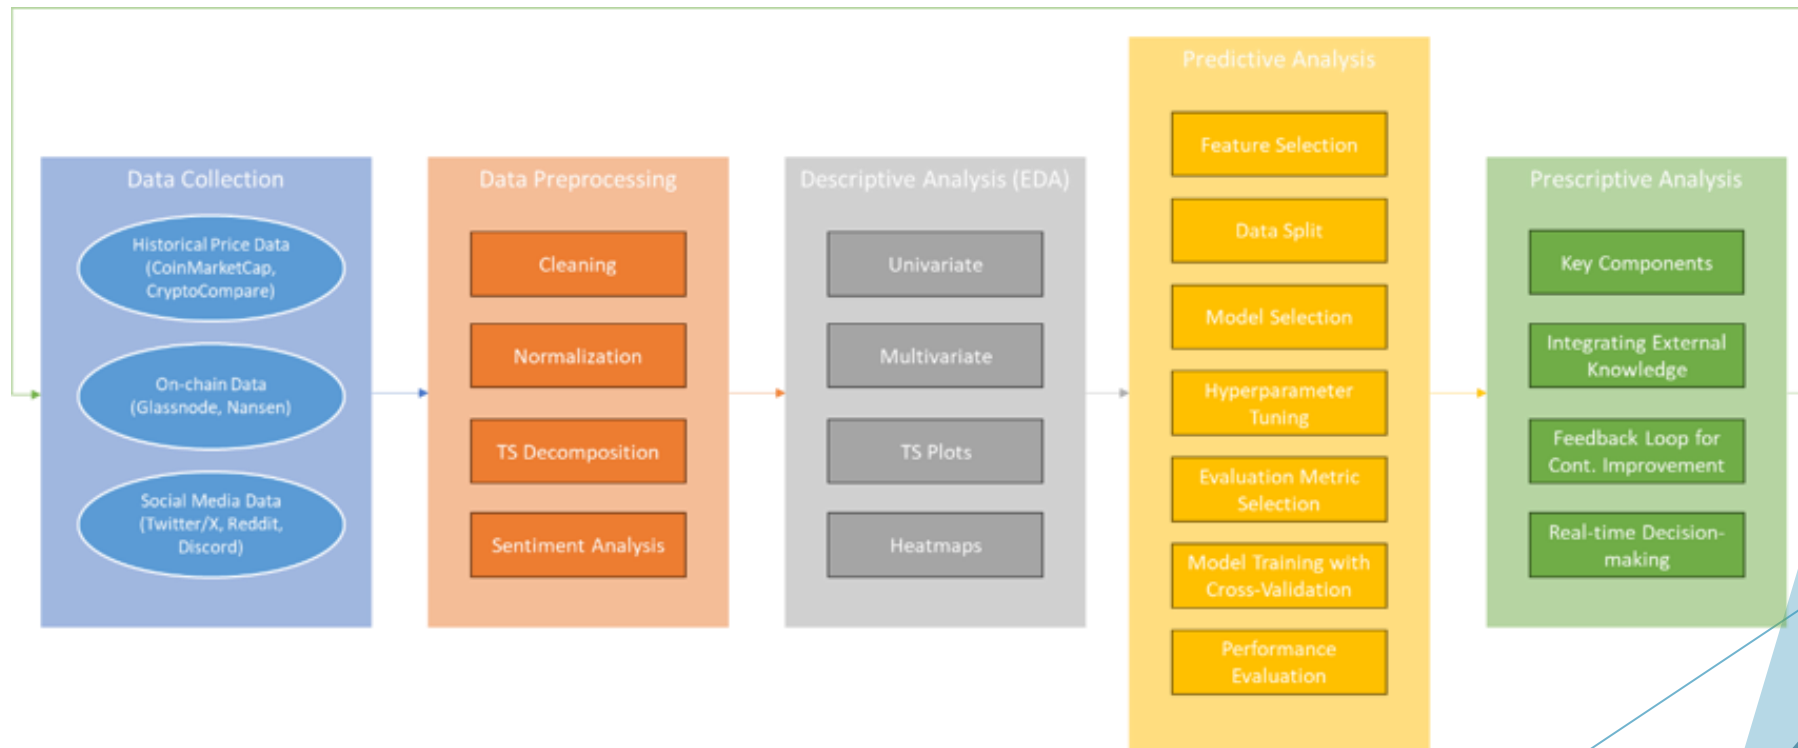
Articole Publicate:

- ▶ "Big data management and NoSQL databases" (2023). Oprea, S.-V., Bâra, A., Oprea, N.. Ovidius University Annals, Economic Sciences Series
- ▶ "Forecasting the Spot Market Electricity Price with a Long Short-Term Memory Model Architecture in a Disruptive Economic and Geopolitical Context" (2023). Bâra, A., Oprea, S.-V., Băroiu, A.-C.. International Journal of Computational Intelligence Systems
- ▶ "The Impact of Academic Publications over the Last Decade on Historical Bitcoin Prices Using Generative Models" (2024). Bâra, A., Oprea, S.-V.. Journal of Theoretical and Applied Electronic Commerce Research
- ▶ "A Descriptive-Predictive-Prescriptive Framework for the Social-Media-Cryptocurrencies Relationship" (2024). Băroiu, A.-C., Bâra, A.. Electronics

Articole in curs de redactare/ publicare:

- ▶ Băroiu, A.-C.; Bâra, A. Forecasting the Bitcoin Price with a Large Language Model leveraging the Social-Media - Cryptocurrencies Relationship. Articolul este in curs de redactare si va fi trimis spre evaluare/publicare in cadrul unei conferinte internationale
- ▶ Oprea, S.V., Bâra, A., A LLM-based Recommendation System for Bitcoin Trading Strategy / A data-preprocessing approach for improving machine learning algorithms for classifying customers. Articolul este in curs de concepere/redactare si va fi trimis spre evaluare/publicare in cadrul unei conferinte internationale

Dezvoltarea unui Framework descriptiv - predictiv - prescriptiv pentru relația social media - cryptomonedede



Dezvoltarea unui Framework descriptiv - predictiv - prescriptiv pentru relația social media - cryptomonedede

- ▶ **Metodologie sistematică pentru analiza criptomonedelor și social media:** Acoperă întregul proces de la colectarea datelor la luarea deciziilor prescriptive, încorporând sentimentul rețelelor sociale, date istorice de preț și valori on-chain.
- ▶ **Tehnologii avansate și adaptabilitate:** Utilizează tehnici de machine learning și deep learning pentru a face față volatilității pieței criptomonedelor. Este primul cadru de acest gen, esențial pentru cercetători, investitori și factori de decizie.
- ▶ **Abordarea disparității informaționale:** Transformă abundența de date nestructurate în informații practice și valoroase, oferind o bază solidă pentru analiza și predicția pieței criptomonedelor.

Dezvoltarea unui Framework descriptiv - predictiv - prescriptiv pentru relația social media - cryptomonedede

- ▶ **Analiza și modelarea datelor:** Începe cu Analiza Exploratorie a Datelor (EDA) pentru înțelegere preliminară și generare de ipoteze, urmată de modelarea predictivă pentru prognoze, cu accent pe evitarea overfitting-ului. Analiza prescriptivă oferă recomandări concrete pentru luarea deciziilor.
- ▶ **Proces decizional structurat:** Implementează un proces în 4 pași - evaluarea datelor, planificarea strategică, execuția și monitorizarea continuă. Include strategii de alocare a investițiilor, atenuare a riscului și analiză a lichidității.
- ▶ **Strategii de investiții avansate:** Propune diversificarea portofoliului bazată pe corelații negative între active și oferă instrumente pentru evaluarea capacității de a răspunde rapid la schimbările pieței.

Dezvoltarea unui Framework descriptiv - predictiv - prescriptiv pentru relația social media - cryptomonedede

- ▶ **Provocări și limitări curente:** Recunoaște simplificările în EDA și modelarea predictivă, precum și provocările legate de robustețea în context real. Abordează dificultățile în gestionarea volatilității datelor și a riscului de overfitting.
- ▶ **Îmbunătățiri și adaptări viitoare:** Propune extinderea algoritmilor de reglare a hiperparametrilor, integrarea reglementărilor în schimbare (ex: Anti-Spălarea Banilor, Know Your Client) și dezvoltarea unei aplicații în timp real pentru testarea completă a cadrului.
- ▶ **Direcții de cercetare și dezvoltare:** Sugerează testarea pe diverse seturi de date și condiții de piață, implementarea sistemelor early warning și backtesting, precum și explorarea tehnicilor mai avansate de extragere a sentimentelor pentru o analiză mai nuanțată a pieței.

Imbunătățirea framework-ului DPP cu ajutorul LLM-urilor

- ▶ **Procesarea și interpretarea automată a datelor:** LLM-urile pot analiza rapid seturi mari de date, extrăgând informații relevante și identificând trenduri, pattern-uri și anomalii care ar putea scăpa analizei umane. Acestea pot genera rezumate în limbaj natural, transformând datele tehnice în rapoarte ușor de înțeles pentru non-specialiști.
- ▶ **Integrarea cunoștințelor și formularea întrebărilor:** LLM-urile pot accesa și incorpora informații din surse externe relevante, oferind o perspectivă mai largă asupra datelor analizate. În plus, pot sugera direcții de investigație și formula întrebări pentru aprofundarea analizei, ghidând utilizatorul către aspecte importante care necesită atenție.

Îmbunătățirea framework-ului DPP cu ajutorul LLM-urilor

- ▶ **Optimizarea și interpretarea modelelor:** LLM-urile pot evalua rapid diferite modele și selecta cea mai bună opțiune, identificând caracteristicile cele mai relevante pentru predicții precise. Ele pot traduce output-ul tehnic al modelelor în explicații clare și accesibile, oferind context și interpretare pentru predicțiile generate.
- ▶ **Îmbunătățirea acurateței și relevanței predicțiilor:** LLM-urile permit generarea de predicții condiționale bazate pe diferite scenarii "what-if", oferind o imagine mai nuanțată a posibilelor rezultate viitoare. Ele pot evalua incertitudinea și robustețea predicțiilor, identificând potențiale limitări. În plus, pot integra cunoștințe cauzale în modelare, îmbunătățind acuratețea predicțiilor.

Îmbunătățirea framework-ului DPP cu ajutorul LLM-urilor

- ▶ **Generarea și evaluarea recomandărilor:** LLM-urile pot transforma predicțiile în acțiuni concrete și fezabile, personalizând recomandările în funcție de context. Ele pot analiza impactul potențial al acțiunilor recomandate, identificând riscuri și beneficii. În plus, pot oferi justificări clare pentru fiecare recomandare, permițând utilizatorilor să înțeleagă procesul decizional.
- ▶ **Adaptare și rafinare prin dialog:** LLM-urile pot ajusta recomandările luând în considerare constrângerile practice, bugetare sau etice. Ele facilitează un dialog natural cu utilizatorul, permițând clarificări și ajustări continue. Acest proces iterativ îmbunătățește calitatea și relevanța recomandărilor finale.

Discuții

- ▶ **Impactul integrării LLM-urilor în DPP:** Incorporarea LLM-urilor în framework-ul DPP poate oferi o îmbunătățire semnificativă în toate etapele analizei - descriptivă, predictivă și prescriptivă. Acest lucru permite o analiză mai profundă, mai nuanțată și mai accesibilă a datelor, conducând la decizii mai informate.
- ▶ **Provocări și limitări:** Deși promițătoare, această abordare prezintă și provocări, cum ar fi potențialul de halucinări al LLM-urilor, necesitatea de a valida și verifica output-ul generat, precum și preocupări legate de confidențialitatea datelor și costurile computaționale asociate.

Direcții viitoare

- ▶ **Dezvoltarea de LLM-uri specializate:** Crearea de modele lingvistice antrenate specific pentru analiza datelor și forecasting, care să înțeleagă mai bine concepte statistice și economice.
- ▶ **Integrarea mai profundă cu tehnici de cauzalitate:** Explorarea modalităților de a incorpora mai eficient înțelegerea relațiilor cauzale în procesul de analiză și predicție.
- ▶ **Îmbunătățirea interacțiunii om-mașină:** Dezvoltarea de interfețe mai naturale și intuitive pentru interacțiunea cu framework-ul DPP augmentat cu LLM-uri.
- ▶ **Evaluarea și mitigarea bias-urilor:** Studiul potențialelor bias-uri introduse de LLM-uri în procesul de analiză și decizie.

Concluzii

- ▶ **Potențial transformativ:** Integrarea LLM-urilor în framework-ul DPP are potențialul de a transforma fundamental modul în care organizațiile abordează analiza datelor și luarea deciziilor.
- ▶ **Îmbunătățirea accesibilității:** Această abordare face analiza avansată a datelor mai accesibilă pentru un public mai larg.
- ▶ **Necesitatea unei abordări echilibrate:** Este crucial să se balanseze entuziasmul pentru noile capacități cu o evaluare critică și riguroasă a rezultatelor, asigurând acuratețea și fiabilitatea analizelor.
- ▶ **Viitorul analizei datelor:** Pe măsură ce tehnologia LLM evoluează, se poate anticipa o integrare din ce în ce mai mare între analiza tradițională a datelor și capacitățile avansate de procesare a limbajului natural, deschizând noi orizonturi în domeniul data science și business intelligence.

Q&A

