

SMARTMONY: UN AGENT FINANCIAR BAZAT PE MODELE LINGVISTICE DE MARI DIMENSIUNI

Tudor Zgîmbău^{1*}

¹⁾ *Universitatea Alexandru Ioan Cuza, Iași, România*

Rezumat

În ultima perioadă am asistat la o creștere exponențială a adoptării instrumentelor bazate pe inteligență artificială (IA), în paralel cu un entuziasm tot mai mare din partea dezvoltatorilor experimentați de a lansa soluții inovatoare pe piață. Datorită flexibilității sale intrinseci și a capacității de a imita funcțiile cognitive umane, IA - în special modelele lingvistice de mari dimensiuni (LLM – „large language models”, în engleză) - a devenit o alegere ideală pentru o varietate de aplicații din diverse domenii. Valorificând aceste capacități avansate, lucrarea prezintă modul de creare și funcționare a unui agent financiar bazat pe IA. Construit pe o arhitectură sofisticată care integrează mai multe LLM-uri interconectate prin API-uri (Application Programming Interface - Interfață de programare a aplicațiilor, în engleză), are la bază în principal modelul GPT-4o, dar este adaptabil și altor modele avansate. Proiectat pentru a aborda problema persistentă a deficitului de educație financiară, răspândită în economii diverse, dar și pentru a sprijini integrarea indivizilor în ecosistemul financiar actual, agentul propus asistă utilizatorii în îndeplinirea sarcinilor financiare uzuale, în înțelegerea conceptelor financiare teoretice sau aplicate, precum și în realizarea unor analize detaliate ale documentelor de specialitate. În plus, sistemul dispune de un mod inovator „istoric”, care permite analiza comparativă a perspectivelor doctrinare asupra temelor financiare. Dezvoltarea sa a inclus tehnici iterative de inginerie a prompt-urilor și testări cantitative și calitative cu potențiali utilizatori, iar performanța sa a fost validată printr-o testare extinsă în mai multe arii ale expertizei financiare. De asemenea, agentul propus este eficient din punct de vedere al costurilor, atât în mărime absolută, cât și comparativ cu multe soluții existente pe piață.

Cuvinte-cheie: finanțe, inteligență artificială, chatbot, educație financiară.

Clasificare JEL: A20, G00, B00

Abstract

In recent times, we have witnessed an exponential increase in the adoption of tools based on artificial intelligence (AI), accompanied by a growing enthusiasm among experienced developers to launch innovative solutions on the market. Due to its intrinsic flexibility and its ability to mimic human cognitive functions, AI - particularly large language models (LLMs) - has become an ideal choice for a wide range of applications across various fields. Leveraging these advanced capabilities, this paper presents the

* Autor de contact, **Zgîmbău Tudor** – tudor.zgimbau@gmail.com

creation and operation of an AI-powered financial agent. Built on a sophisticated architecture that integrates multiple LLMs interconnected via APIs (Application Programming Interfaces), the system is primarily based on the GPT-4o model but is adaptable to other advanced models as well. Designed to address the persistent issue of financial illiteracy - prevalent across diverse economies - and to support individuals in integrating into today's financial ecosystem, the proposed agent assists users in completing routine financial tasks, understanding both theoretical and applied financial concepts, and conducting in-depth analyses of specialized documents. Additionally, the system features an innovative "historical" mode that enables comparative analysis of doctrinal perspectives on financial topics. Its development included iterative prompt engineering techniques and both quantitative and qualitative testing with potential users, and its performance was validated through extensive testing across multiple areas of financial expertise. Furthermore, the proposed agent is cost-effective, both in absolute terms and in comparison with many existing market solutions.

Keywords: finance, artificial intelligence, chatbot, financial education

JEL classification: A20, G00, B00

Introducere

Într-o lume în care schimbarea devine singura constantă certă, digitalizarea accelerată și dezvoltarea rapidă a tehnologiilor inteligente impun revizuirea continuă a modului în care indivizii interacționează cu domeniul financiar. Ultimii ani au adus o creștere exponențială a utilizării instrumentelor bazate pe inteligență artificială (IA), în paralel cu un avânt semnificativ al dezvoltatorilor de software competenți care urmăresc introducerea unor soluții inovatoare pe piață. Prin capacitatea sa de a imita complexitatea și flexibilitatea funcționării rețelelor neuronale umane, IA a devenit rapid o alternativă extrem de promițătoare în rezolvarea diverselor sarcini, de la simplele activități cotidiene până la cele mai sofisticate probleme din diverse domenii.

În acest context, utilizarea modelelor lingvistice avansate, precum GPT-4o, poate facilita semnificativ integrarea indivizilor în ecosistemul financiar contemporan, contribuind astfel activ la diminuarea deficitului de educație financiară care afectează negativ populațiile multor state, indiferent de nivelul lor de dezvoltare economică. Deși importanța alfabetizării financiare a fost recunoscută unanim în literatura de specialitate și de către autoritățile competente din întreaga lume, metodele tradiționale s-au dovedit deseori insuficiente sau greu extensibile la nivel național. Tocmai de aceea, introducerea unui chatbot în forma unui agent AI avansat, capabil să sprijine utilizatorii în îndeplinirea unei game largi de sarcini financiare, de la explicarea conceptelor teoretice până la analiza complexă a documentelor relevante din domeniu, reprezintă un progres semnificativ.

Prezenta lucrare propune crearea unui astfel de sistem bazat pe modelul GPT-4o, conectat la surse actualizate de informație și dotat cu un mod special, numit „istoric”, ce permite utilizatorilor să efectueze analize comparative ale diferitelor perspective doctrinare asupra problemelor financiare. Realizarea sistemului a presupus utilizarea riguroasă a unor tehnici iterative de inginerie a prompt-urilor, precum și testarea extinsă a eficienței și utilității acestuia în diverse scenarii de utilizare. Evaluările cantitative și calitative efectuate

asupra unui grup de potențiali utilizatori au demonstrat că instrumentul propus nu doar completează eficient, ci chiar depășește capacitățile modelelor lingvistice standard și ale motoarelor de căutare convenționale în rezolvarea problemelor specifice din sfera financiară.

1. Recenzia literaturii științifice

În literatura de specialitate, este evidențiat faptul că, pentru anumite sarcini precum purtarea de conversații pe aplicațiile de mesagerie, chatbot-urile bazate pe inteligență artificială pot fi mai eficace decât oamenii (Adamopoulou, 2020, p. 380). Adamopoulou (2020, p. 380) arată că astfel de sisteme aduc economii semnificative în operarea departamentelor de servicii clienți. În același sens, Onabowale (2024, p. 4845) afirmă că integrarea instrumentelor bazate pe IA „a fost instrumentală în abordarea ineficiențelor, îmbunătățirea experiențelor clienților și promovarea incluziunii financiare”, permițând instituțiilor să se extindă operațional fără costuri proporționale. Mai mult, Ahmad et al. (2025, p. 10) notează că IA „îmbunătățește eficiența și creează noi oportunități pentru profesioniștii financiari de a se conecta mai eficient cu clienții”.

În același timp, educația și alfabetizarea financiară reprezintă domenii profund studiate de cercetătorii în domeniu și, în același timp, o preocupare curentă a multor guverne. În sprijinul impactului educației financiare asupra comportamentelor financiare, Allgood și Walstad (2016, p. 675) arată că alfabetizarea are șanse mari de a schimba comportamentele financiare în cinci domenii-cheie (carduri de credit, investiții, credite, asigurări și consultanță financiară), iar Kaiser și Menkhoff (2017, p. 611) adaugă că educația financiară influențează și mai puternic alfabetizarea financiară. În același timp, OECD (2020, p. 63) raportează un scor mediu de doar 12,7 puncte (sub 61% din maximum) pentru alfabetizarea financiară la nivel global, subliniind necesitatea implementării unor soluții aplicabile în țări cu grad de dezvoltare economico-socială variat. Un posibil instrument didactic este prezentat în studiul lui Niszezota și Abbas (2023, p. 1), care evidențiază că GPT-4 atinge un scor de 99% în teste de alfabetizare financiară, sugerând că acesta poate fi folosit cu succes pentru educarea persoanelor ce dispun de cunoștințe limitate în domeniu. În sprijinul acestei idei, putem considera studii care susțin utilizarea IA în scop didactic (Cao et al., 2023, p. 4; D’Mello și Graesser, 2013, p. 1). Cao et al. (2023, p. 4) prezintă un studiu de caz ce concluzionează că chatbot-urile bazate pe modele lingvistice de mari dimensiuni pot fi utilizate ca material didactic pentru predarea cursurilor universitare de informatică, iar D’Mello și Graesser (2013, p. 1) prezintă un instrument construit pe baza unor metode de lingvistică computațională numit AutoTutor, ce a demonstrat îmbunătățiri în cunoștințele studenților echivalente unei avansări de o literă în sistemul alfabetic de evaluare după doar 30–60 de minute de conversație.

Lakkaraju et al. (2023, p. 105) raportează o „creștere a aplicării modelelor lingvistice în finanțe datorită abilității lor de a procesa volum mare de date nestructurate și de a extrage informații valoroase”. Li et al. (2023, p. 380) propun îmbunătățirea modelelor lingvistice de mari dimensiuni prin tehnici de pre-antrenare, învățare ghidată pe date reprezentative și personalizare, arătând câștiguri de performanță semnificative față de LLM-urile generale în sarcini precum analiza sentimentelor, dialog și rezumare. În plus, Reher și Sokolinski (2024, p. 35) concluzionează că gestionarea averii nu mai este un serviciu exclusivist și că robo-consultanții răspund cererii investitorilor de clasă mijlocie, democratizând accesul la astfel de servicii.

Analiza performanțelor modelelor IA arată atât progrese, cât și limitări. Hean et al. (2025, p. 1) notează că modelele „ating o acuratețe medie de aproximativ 70%” în sarcinile legate de gestionarea finanțelor personale, dar „prezintă limitări notabile în anumite domenii”. În legătură cu performanțele IA în domenii specifice, Varnum et al. (2024) propun conceptul de „Historical Large Language Models” (HLLM) capabile să simuleze personalitățile unor figuri istorice, deschizând posibilitatea implementării modului „istoric” descris în lucrarea de față, care permite analiza comparativă a perspectivelor doctrinare de-a lungul timpului.

Literatura prezentată demonstrează relevanța SmartMony atât pentru eficiența operațională și educație financiară, cât și pentru inovație metodologică în interpretarea doctrinării istorice a conceptelor financiare.

2. Metodologia cercetării

Pentru realizarea acestui agent financiar bazat pe IA am dezvoltat o arhitectură modulară și ușor extensibilă, prezentată detaliat în cele ce urmează. Un prim pas în determinarea serviciilor necesare obținerii răspunsului este identificarea cerințelor privind referințele bibliografice. Agentul, numit Mony, identifică dacă întrebarea se referă la o acțiune sau o îndrumare concretă (de exemplu, „Cum îmi fac asigurare CASCO în România?”) sau dacă aceasta este mai complexă și necesită consultarea literaturii de specialitate. În primul caz, simpla dotare cu capacități de accesare a internetului și ghidarea răspunsului prin prompt-ul de sistem este suficientă. În cel de-al doilea caz, este necesară adoptarea unei arhitecturi mai sofisticate, prezentată în Figura nr. 1. Această arhitectură implică utilizarea mai multor modele lingvistice de mari dimensiuni (LLM-uri) conectate printr-un API central, având scopuri specifice clar definite.

De remarcat este flexibilitatea alegerii modelelor folosite pentru funcționarea agentului. Avantajul existenței unor opțiuni al căror cod sursă este deschis face posibilă modularizarea componentelor și găzduirea acestora pe servere private, nefiind necesară o conexiune la internet a modelului sau plata unor servicii de găzduire sau de IA cu cost lunar sporit.




Figura nr. 1. Arhitectura agentului financiar

Sursa: Prelucrare autor după literatura de specialitate

În continuare, voi descrie traseul parcurs de utilizator de la interogarea agentului și până la primirea răspunsului pentru această arhitectură. În primul rând, interogarea utilizatorului este procesată de un API central, care o redirecționează spre primul LLM. Acesta are scopul de a o rezuma sub forma unei interogări și mai concise, care va fi trimisă mai apoi spre API-ul CORE¹. Prompt-ul de sistem care antrenează acest LLM este, tradus în limba română: „*Scopul tău este să rezumi prompt-ul utilizatorului într-o interogare care va fi transmisă către API-ul CORE (core.ac.uk) pentru a recupera articole științifice și documente relevante. Asigură-te că interogarea este scurtă, dar păstrează esența a ceea ce îți dorește utilizatorul.*” Am considerat oportună păstrarea prompt-urilor de sistem în limba engleză, deoarece modelele au fost antrenate pe o proporție superioară de materiale în limba engleză față de cea română.

După primirea interogării de către API-ul central, aceasta este redirecționată către API-ul CORE, o bază de date cu sursă deschisă ce conține articole de cercetare cu acces deschis², iar acesta returnează o colecție de articole și rezumate relevante căutării efectuate. Este posibilă setarea unei limite cu privire la numărul de articole returnate, care poate ajusta gradul de profunzime al analizei, direct proporțional cu timpul de procesare a răspunsului.

A treia parte implică un nou LLM care procesează pe rând articolele sau rezumatele acestora (datorită limitei contextuale) în scopul obținerii unor rezumate standardizate pe baza cărora va fi făcută analiza. Prompt-ul de sistem al LLM-ului este, tradus în limba română: „*Ești cel mai util rezumator din lume. Păstrează fiecare detaliu important oferind un rezumat concis. Acest rezumat este destinat scopurilor științifice și va fi introdus într-un alt model. Dacă există o problemă care te împiedică să generezi rezumatul, menționează explicit acest lucru. Trebuie să păstrezi rezumatul cât mai aproape de 400 de tokeni, dar nu mai mult, dacă articolul are peste 400 de tokeni. Dacă are mai puțin, redă întregul articol. Nu oferi un rezumat al rezumatului.*” Opțiunea celor 400 de tokeni este dată de limita contextuală de 128.000 de tokeni a modelului GPT-4o, dar poate fi extinsă în funcție de preferința utilizatorului. În contextul accelerării dezvoltării IA și apariției modelelor cu capacități superioare din punct de vedere al contextualizării, consider oportună setarea unei limite superioare în viitorul apropiat.

Ultima parte reprezintă generarea efectivă a analizei de interes pentru utilizator. Aceasta se face cu ajutorul celui de-al treilea model lingvistic de mari dimensiuni, ținând cont de datele extrase mai devreme. Prompt-ul de sistem pentru acest model este scris în limbajul Markdown pentru a ușura înțelegerea acestuia și vizează următoarele aspecte:

- În cazul modelelor probabilistice există posibilitatea apariției așa-numitelor „halucinații”. Acestea reprezintă informație inventată de către modele, care este prezentată drept sursă autentică. În consecință, este periculoasă oferirea permisiunii modelului de a-și baza răspunsul pe propria bază de date din care au fost memorate date în timpul antrenamentului. În experimentele empirice realizate, toate modelele realizate de către compania OpenAI și de către alți competitori au oferit în răspunsurile lor referințe bibliografice fără surse ușor verificabile, au inventat link-uri și au prezentat alte simptome similare halucinațiilor. Modelul a mai fost instruit să păstreze standarde etice ridicate în oferirea răspunsurilor.
- Din motive ce țin de eficiența operațională (în principal de costuri), modelului îi este impusă o dimensiune maximă a răspunsurilor. Pentru a evita posibile

¹ <https://api.core.ac.uk>

² <https://core.ac.uk>

probleme legate de acest lucru, s-a impus separarea mesajelor lungi în mai multe părți.

- Există arii din finanțe în care personalizarea răspunsurilor în funcție de profilul de risc al utilizatorului reprezintă un lucru esențial (spre exemplu, domeniul asigurărilor sau cel al piețelor de capital). În consecință, modelul a fost instruit pentru a ține cont de acest lucru.
- Modelele GPT dispun de un mecanism intern care evaluează dacă este necesară o căutare pe internet (acolo unde este posibil) sau nu. Datorită lipsei de control asupra acestui aspect, nu putem afirma cu certitudine că datele expuse de model sunt de actualitate. Din acest considerent, am decis ca, în cazul în care utilizatorii agentului vor prefera aceste LLM-uri, să existe în prompt-ul de sistem indicația ca chatbot-ul să nu răspundă întrebărilor cu privire la entități a căror existență în timp s-a schimbat (cum ar fi ONG-uri, firme, universități etc.), ci mai degrabă ca acesta să direcționeze utilizatorii către site-ul relevant. De asemenea, a fost introdusă indicația efectuării unei căutări pe internet pentru altfel de date a căror stare s-a schimbat din momentul pierderii memoriei LLM-ului (cum ar fi, spre exemplu, anumite reglementări).
- Modelul a fost instruit să ofere cele mai detaliate răspunsuri, cu excepția momentelor când îi este solicitat în mod explicit să nu facă acest lucru.
- De asemenea, modelul a fost instruit să explice întregul proces din spatele răspunsului oferit (spre exemplu, pașii juridici legați de încheierea unei polițe de asigurare).

De asemenea, am testat cu succes introducerea unui așa-numit „mod istoric”: datorită faptului că, în finanțe, multe răspunsuri sunt influențate pregnant de perspectiva doctrinară, am considerat utilă prezentarea unei viziuni comparative în această privință.

3. Rezultate și discuții

În evaluarea sistemului creat s-au avut în vedere mai multe criterii. Pentru întrebările care nu necesită referințe bibliografice, câteva dintre acestea au fost:

- Acuratețea răspunsului
- Optimalitatea lungimii răspunsului ales
- Claritatea răspunsului
- Potrivirea răspunsului cu nivelul de cunoștințe al utilizatorului. Fiind un agent destinat și cercetării științifice, s-a considerat un nivel mediu spre ridicat de cunoștințe al utilizatorului pentru întrebările cu grad mediu de dificultate, dacă acesta nu a fost menționat în mod explicit.

Pentru întrebările ce necesitau referințe bibliografice, câteva dintre criterii au fost:

- Potrivirea dintre referințele alese și cerințele utilizatorului
- Capacitatea modelului de a înțelege referințele primite
- Capacitatea modelului de a judeca pe baza referințelor primite
- Acuratețea răspunsului
- Claritatea răspunsului
- Respectarea cerinței de a nu introduce referințe suplimentare nejustificate

Pe baza acestor criterii s-a realizat optimizarea iterativă a răspunsurilor modelului, până când toate criteriile au fost îndeplinite într-o proporție semnificativă. A fost ținut cont de natura probabilistă a acestuia, prin urmare mai multe răspunsuri pozitive au fost necesare

pentru a concluziona eficiența modelului. Un exemplu de răspuns din partea agentului este prezentat în Figura nr. 2 pentru întrebarea: „Cum se poate reduce deficitul bugetar al unei țări?”. Având în vedere limitările de spațiu, analiza a fost limitată programatic la cinci articole științifice.

Reducerea deficitului bugetar al unei țări necesită un ansamblu coerent de politici fiscale, instituționale și de integrare economică, care să fie aplicate gradual și adaptat contextului național. Pe baza literaturii academice revizuite (vezi sursele de mai jos), iată cele mai solide strategii:

1. Consolidare fiscală structurată
 Sursa: *Policies for economic development*

- **Reducerea cheltuielilor publice neproductive:** Eliminarea subvențiilor ineficiente și prioritizarea investițiilor în infrastructură, educație și sănătate.
- **Îmbunătățirea colectării fiscale:** Lărgirea bazei de impozitare și eficientizarea administrației fiscale.
- **Reformarea sistemului de prețuri publice și tarife:** Eliminarea distorsiunilor din piețele sectoriale, care creează dezechilibre bugetare.

2. Integrarea economică și deschiderea comercială raționalizată
 Sursa: *How does Trade openness Influence Budget Deficits?*

- **Deschiderea către comerț poate ajuta la echilibrul bugetar doar dacă este gestionată prin politici comerciale inteligente.**
- **"Deschiderea naturală"** (dependența de exporturi/importuri) poate crește instabilitatea și agrava deficitul.
- **"Deschiderea prin politici comerciale"**, în schimb, adesea favorizează surplusuri bugetare, prin atragerea investițiilor și stimularea creșterii economice.

3. Considerarea deficitului cvasi-fiscal
 Sursa: *Estimating quasi-fiscal deficits in a consistent framework: the case of Madagascar*

- Este esențial să se includă și pierderile instituțiilor publice (ex. bănci centrale) în calculul deficitului.
- Excluderea acestora poate duce la politici ineficiente, subestimând adevărata presiune fiscală.

4. Reforme structurale și eficientizarea resurselor
 Sursa: *How the macroeconomic environment affects human resource development*

- **Eliminarea distorsiunilor în piețele muncii și capitalului** – adesea generate de protecționism sau reglementări ineficiente.
- **Promovarea investițiilor private** în formarea profesională poate reduce presiunea asupra cheltuielilor publice.
- **Reforme structurale**, susținute de instituții internaționale (ex. FMI, Banca Mondială), au arătat efecte pozitive în consolidarea bugetară.

↓

Sumar esențial

Măsură	Impact principal
Reforma fiscală și cheltuieli prioritizate	Stabilitate macroeconomică
Politici comerciale bine calibrate	Creștere veniturilor bugetare
Considerarea deficitului cvasi-fiscal	Acuratețe în politici
Reformă structurală și eficiență în resurse	Reducerea presiunii fiscale

Dorești să-ți explic aplicabilitatea acestor măsuri pentru România sau o altă țară anume? Sau să intrăm în detalii privind un set concret de reforme pentru un domeniu specific (de exemplu: pensii, sănătate, educație)?

Fig. 2: Exemplu de răspuns al agentului financiar
 Sursa: Prelucrare agent după baza de date CORE

La finalul răspunsului, modelul oferă o bibliografie cu toate datele disponibile în baza de date despre articolul respectiv.

De asemenea, a fost realizată o evaluare de tip mixt pe un eșantion de 50 de potențiali utilizatori ai agentului, cu un nivel variabil de cunoștințe din zona financiară. Aceștia au fost rugați să evalueze motorul de căutare Google, aplicația ChatGPT (bazată pe modelul GPT-4o) și modelul SmartMony pe o scară de la 1 la 5, cu următoarea semnificație:

- 1 – răspuns imprecis sau greșit
- 2 – răspuns vag, incoerent sau parțial greșit
- 3 – răspuns de calitate medie din toate punctele de vedere
- 4 – răspuns precis, dar foarte greu de înțeles
- 5 – răspuns precis și ușor de înțeles

Întrebările puse au fost:

- „În contextul unei recesiuni economice iminente, cum ai construi o strategie diversificată de investiții pentru a echilibra protecția capitalului cu oportunitățile de creștere?”
- „Cum îmi pot face asigurare CASCO în România?”
- O întrebare de interes pentru cel chestionat. A fost ideal să fie o întrebare complicată (ex: cum funcționează modelele dividend discount), caz în care a existat opțiunea de a solicita modelului o explicație adaptată la nivelul de cunoștințe sau o întrebare mai simplă, dar complicată ca proces (ex: cum funcționează contractul cu un broker pe piața de capital).
- „Modul istoric. Care sunt abordările asupra finanțelor publice?”

Mediile obținute sunt prezentate în Tabelul 1:

Tabelul nr. 1. Mediile obținute de aplicațiile evaluate

Aplicația	Întrebarea 1	Întrebarea 2	Întrebarea 3	Întrebarea 4
Google	3,66	2,81	3,25	3,66
ChatGPT	4,08	3,81	4,16	4,08
SmartMony	4,25	4,27	4,5	4,25

Sursa: Chestionar realizat de autor

De asemenea, a fost cerut feedback calitativ cu privire la utilizarea modelului și au avut loc conversații aprofundate. Concluzia unanimă a chestionarului și a feedback-ului primit este că SmartMony prezintă capacități superioare soluțiilor existente pe piață și poate contribui la:

- Automatizarea anumitor activități financiare
- Susținerea utilizatorilor în procesul de educație financiară
- Documentarea cu privire la anumite aspecte de specialitate
- Înțelegerea perspectivelor doctrinare în finanțe

În același timp, întregul proces de dezvoltare al agentului a costat doar cinci dolari americani în credite OpenAI, ceea ce sugerează eficiența sporită a soluției alese din punct de vedere al costurilor. Prin comparație, abonamentul la un serviciu similar oferit de aceeași companie are un cost ce variază între 20 și 200 USD.

Concluzii

Lucrarea de față a prezentat crearea, arhitectura și testarea unui agent financiar inovator, denumit Mony, construit pe baza modelelor lingvistice de mari dimensiuni, în special GPT-4o, cu scopul de a sprijini alfabetizarea financiară și de a eficientiza procesul de accesare a informațiilor relevante din domeniul financiar. Prin integrarea unor tehnici avansate de inginerie a prompt-urilor, a unor filtre anti-halucinație și a unui mod istoric dedicat analizei doctrinare, Mony reușește să depășească limitările modelelor generice sau ale motoarelor de căutare clasice, oferind răspunsuri precise, bine documentate și adaptate profilului utilizatorului.

Rezultatele testării cantitative și calitative arată performanțe superioare ale modelului în raport cu alte soluții consacrate, atât din punctul de vedere al acurateței, cât și al clarității și relevanței răspunsurilor. De asemenea, eficiența din punct de vedere al costurilor face din acest agent o alternativă viabilă și sustenabilă pentru o gamă largă de utilizatori, de la studenți și cercetători până la utilizatori interesați de îmbunătățirea nivelului de educație financiară. Prin adaptabilitatea sa, rigurozitatea metodologică și potențialul educativ, acesta poate contribui în mod semnificativ la transformarea modului în care indivizii accesează, înțeleg și utilizează informațiile financiare într-o societate din ce în ce mai digitalizată. În consecință, fac următoarele recomandări legate de implementarea modelului și de adaptarea politicilor la inovația tehnologică:

- Este esențial să fie aleasă varianta optimă de găzduire a modelului, ținând cont, spre exemplu, de reglementările GDPR în vigoare și de preferințele utilizatorilor pentru stocarea datelor.
- Costurile reduse ale agentului și capacitatea sa de a finaliza sarcinile într-un timp mult mai redus decât cel uman fac oportună implementarea acestuia pentru comunitățile marginalizate și în medii cu bugete reduse. Astfel, agentul poate reprezenta o metodă cu costuri minime de creștere a nivelului de educație financiară.
- Recomand folosirea agentului ca material didactic interactiv în cursuri obligatorii sau opționale din programele învățământului preuniversitar, dar și ca potențială aplicație de studiu în mediul universitar specializat în economie.
- Pentru a beneficia la maximum de potențialul tehnologic, consider benefică realizarea unui studiu controlat randomizat pentru a prezenta științific beneficiile aduse de utilizarea agentului și, mai apoi, promovarea acestuia în spațiul online pentru a-i lărgi sfera de impact.

Bibliografie

1. **Adamopoulou, E. and Moussiades, L. (2020)** ‘An overview of Chatbot Technology’, in Maglogiannis, I., Iliadis, L. and Pimenidis, E. (eds.) *Artificial Intelligence Applications and Innovations*. Cham: Springer, pp. 373–383. Available at https://doi.org/10.1007/978-3-030-49186-4_31.
2. **Ahmad, A., Al-Harbi, A. and Al-Ghamdi, A. (2025)** ‘The impact of AI on financial professionals’, *Journal of Next-Generation Research* 5.0, 1(2). Available at: https://www.researchgate.net/publication/388928528_The_Impact_of_AI_on_Financial_Professionals (Accessed: 31 July 2025).
3. **Allgood, S. and Walstad, W. B. (2015)** ‘The effects of perceived and actual financial literacy on financial behaviors’, *Economic Inquiry*, 54(1), pp. 675–697. Available at: <https://doi.org/10.1111/ecin.12255>.

4. **Cao, C. C., Ding, Z., Lin, J. and Hopfgartner, F. (2023)** ‘AI chatbots as multi-role pedagogical agents: transforming engagement in CS education’, *arXiv* [preprint]. Available at: <https://arxiv.org/abs/2308.03992> (Accessed: 31 July 2025).
5. **D'Mello, S. and Graesser, A. (2013)** ‘AutoTutor and Affective AutoTutor: learning by talking with cognitively and emotionally intelligent computers that talk back’, *ACM Transactions on Interactive Intelligent Systems*, 2(4), p. 23. Available at: <https://doi.org/10.1145/2395123.2395128>.
6. **Hean, O., Saha, U. and Saha, B. (2025)** ‘Can AI help with your personal finances?’, *Applied Economics*, pp. 1–9. Available at: <https://doi.org/10.1080/00036846.2025.2450384>.
7. **Kaiser, T. and Menkhoff, L. (2017)** ‘Does financial education impact financial literacy and financial behavior, and if so, when?’, *The World Bank Economic Review*, 31(3), pp. 611–630. Available at: <https://doi.org/10.1093/wber/lhx018>.
8. **Lakkaraju, K., Jones, S. E., Vuruma, S. K. R., Pallagani, V., Muppasani, B. C. and Srivastava, B. (2023)** ‘LLMs for financial advisement: a fairness and efficacy study in personal decision making’, in *Proceedings of the Fourth ACM International Conference on AI in Finance*, pp. 100–107. Available at: <https://doi.org/10.1145/3604237.3626867>.
9. **Li, Y., Wang, S., Ding, H. and Chen, H. (2023)** ‘Large language models in finance: a survey’, in *Proceedings of the Fourth ACM International Conference on AI in Finance (ICAIF '23)*, pp. 374–382. Available at: <https://doi.org/10.1145/3604237.3626869>.
10. **Niszczoła, P. and Abbas, S. (2023)** ‘GPT has become financially literate: insights from financial literacy tests of GPT and a preliminary test of how people use it as a source of advice’, *Finance Research Letters*, 58, 104333. Available at: <https://doi.org/10.1016/j.frl.2023.104333>.
11. **OECD (2020)** *OECD/INFE 2020 International Survey of Adult Financial Literacy*. Paris: OECD Publishing. Available at: <https://doi.org/10.1787/145f5607-en>.
12. **Onabowale, O. (2024)** ‘The rise of AI and robo-advisors: redefining financial strategies in the digital age’, *International Journal of Research Publication and Reviews*, 6, pp. 4832–4848. Available at: https://www.researchgate.net/publication/393476110_The_Rise_of_AI_and_Robo-Advisors_Redefining_Financial_Strategies_in_the_Digital_Age (Accessed: 31 July 2025).
13. **Reher, M. and Sokolinski, S. (2024)** ‘Robo Advisors and Access to Wealth Management’, *Journal of Financial Economics*. Forthcoming. Available at: <http://dx.doi.org/10.2139/ssrn.3515707> (Accessed: 31 July 2025).
14. **Varnum, M. E. W., Baumard, N., Atari, M. and Gray, K. (2024)** ‘Large language models based on historical text could offer informative tools for behavioral science’, *Proceedings of the National Academy of Sciences of the United States of America*, 121(42), e2407639121. Available at: <https://doi.org/10.1073/pnas.2407639121>.