Universitatea Națională de Știință și Tehnologie
POLITEHNICA București
Școala Doctorală de Inginerie Industrială și Robotică

Decizie CSUD UPB nr. ……. din ……..

REZUMAT TEZĂ DE DOCTORAT

Raymond G. MAIORESCU

Inteligența Artificialã pentru Transformarea Afacerilor

COMISIA DE DOCTORAT

Președinte	**Prof.univ.dr.ing. Cãtãlin Gheorghe AMZA** Universitea POLITEHNICA din Bucureşti
Conducător științific	**Prof.univ.dr.ing.ec. Augustin SEMENESCU** Universitea POLITEHNICA din București
Referent	**Prof.univ.dr.ing. Bujorel-Ionel PAVALOIU** Universitea POLITEHNICA din Bucureşti
Referent	**Prof.univ.dr.ing. Victoria Larisa IVAŞCU** Universitea POLITEHNICA Timişoara
Referent	**Prof.univ.dr.ing. Liviu MOLDOVAN** UMFST “George Emil Palade” Tg. Mureş

BUCUREŞTI 2024

Inteligenta Artificiala pentru Transformarea Afacerilor

Cuprins

Chapter 1 Fundamentele Inteligenței Artificiale 8
1.1 Introducere 8
1.2 Definiția și Caracteristicile Fundamentale ale Inteligenței Artificiale 8
1.2.1 Caracteristici cheie ale sistemelor de inteligență artificială 8
1.3 Clasificările Inteligenței Artificiale 9
1.3.1 Inteligența Artificială Îngustă (IA Slabă) 9
1.3.2 Inteligența Artificială Generală (AGI) 9
1.3.3 Clasificarea funcțională a IA 9
1.4 Învățarea Automată vs. Învățarea Profundă 9
1.4.1 Învățarea Automată (ML) 10
1.4.2 Învățarea Profundă (DL) 10
1.5 IA și Web3: Descentralizare și Autonomie 10
1.5.1 Sinergia dintre IA și Blockchain 10
1.5.2 IA în DAOs (Organizații Autonome Descentralizate) 10
1.6 Percepția Publică și Considerațiile Etice 11
1.6.1 IA în Cultura Populară 11
1.6.2 Confidențialitate, Bias și Transparență 11
1.6.3 IA și Forța de Muncă 11
1.7 Mediul Inteligenței Artificiale: Industrie, Academie și Descentralizare 11
1.7.1 Liderii Tradiționali în IA 11
1.7.2 Platforme IA Descentralizate 12
1.7.3 IA și Geopolitica 12
Chapter 2 Protocolul de Schimb de Date Descentralizat 12
2.1 Introducere 12
2.2 Context: Nevoia unui Schimb de Date Securizat în Producție 13
2.2.1 Provocările Schimbului Tradițional de Date 13
2.3 Schimburile Descentralizate de Date: Principii și Beneficii 13
2.3.1 Cum Funcționează Schimburile Descentralizate de Date 13
2.3.2 Avantajele unui Schimb de Date Descentralizat 13
2.4 Ocean Protocol: Un Cadru pentru Schimbul Descentralizat de Date 14

2.4.1 Caracteristici Cheie ale Ocean Protocol 14
2.4.2 Arhitectura Ocean Protocol 14
2.4.3 NFT-uri de Date și Datatokens 14
2.5 Acces Securizat la Date și Permisiuni 15
2.5.1 Controlul Accesului pe Bază de Roluri (RBAC) 15
2.5.2 Tehnici de Protejare a Confidențialității 15
2.6 Construirea unei Piețe Descentralizate de Date 15
2.6.1 Pașii pentru Implementarea unei Piețe de Date 15
2.6.2 Beneficiile Utilizării Ocean Protocol pentru o Piață de Date 16
2.7 Compute-to-Data: Permiterea IA fără Expunerea Datelor 16
2.7.1 Cum Funcționează Compute-to-Data 16
2.7.2 Aplicații ale Compute-to-Data în Industrie 16
Chapter 3 Intersecția dintre Criptomonede, Blockchain și Sport 17
3.1 Introducere 17
3.2 Sinergia dintre Blockchain și Sport 17
3.2.1 Suprapunerea Demografică 17
3.2.2 Creșterea Fan Tokens și a Colecționabilelor Digitale 18
3.3 Blockchain și Criptomonede în Operațiunile Sportive 18
3.3.1 Criptomonede ca Metodă de Plată 19
3.3.2 Tokenizarea în Sport 19
3.3.3 Contracte Inteligente în Sponsorizări și Acorduri de Jucători 19
3.4 Impactul Blockchain asupra Sponsorizărilor și Parteneriatelor 20
3.4.1 Sponsorizările Criptografice în Sport 20
3.5 Viitorul Blockchain în Sport 20
3.5.1 Bilete Inteligente și Măsuri Anti-Fraudă 20
3.5.2 eSports și Ligi Fantastice Descentralizate 20
3.5.3 Media Sportivă și Monetizarea Conținutului 20
Chapter 4 Evoluția LLM-urilor în Academia 21
4.1 Introducere 21
4.2 Evoluția LLM-urilor în Academia 21
4.2.1 De la Procesare de Text la Inteligență Contextuală 21
4.2.2 Impactul asupra Cercetării și Educației 22

4.3 Provocări Etice în Utilizarea LLM-urilor în Academia 22
4.3.1 Bias-ul în Cercetarea Generată de AI 22
4.3.2 Integritatea Academică și Plagiatul 23
4.4 Abordarea Bias-ului în Cercetarea Asistată de LLM-uri 23
4.4.1 Studiu de Caz: Măsurarea Bias-ului în Output-urile LLM-urilor 23
4.4.2 Strategii de Reducere a Bias-ului 23
4.5 Integritatea Academică în Era Scrierii Asistate de AI 24
4.5.1 Model de Regresie Logistică pentru Detectarea AI 24
4.5.2 Evaluarea Performanței 24
4.5.3 Implicații Etice 24
4.6 Considerații pentru Viitor 24
4.6.1 Consolidarea Ghidurilor Etice 24
Chapter 5 Învățarea Federată în Industria Farmaceutică 25
5.1 Introducere 25
5.2 Provocările Gestionării Datelor 25
5.2.1 Confidențialitatea Datelor și Conformitatea cu Reglementările 25
5.2.2 Securitatea Datelor și Amenințările Cibernetice 25
5.2.3 5.2.3 Integrarea și Interoperabilitatea Datelor 26
5.2.4 Calitatea și Fiabilitatea Datelor 26
5.2.5 Scalabilitatea și Analiza Big Data 26
5.3 Învățarea Federată pentru Gestionarea Datelor 26
5.3.1 Cum Funcționează Învățarea Federată? 26
5.3.2 Avantaje Cheie 27
5.4 Implementarea Învățării Federate 27
5.4.1 Infrastructura și Securitatea 27
5.4.2 5.4.2 Conformitatea Reglementărilor și Aspecte Etice 27
5.4.3 Direcții de Cercetare Viitoare 27
5.5 Compute-to-Data: Un Cadru pentru Protejarea Confidențialității 27
5.6 Abordarea Riscurilor și Provocărilor 28
5.6.1 Eterogenitatea Datelor și Bias-ul 28
5.6.2 Securitate și Confidențialitate 28
5.6.3 Etică și Guvernanță IA 28

Chapter 6 Domenii ENS și NFT-uri pentru Entități de Afaceri Integrate 28
6.1 Introducere 28
6.2 Domenii ENS și NFT-uri 29
6.3 Crearea unei entități de afaceri cu domenii ENS și NFT-uri 29
6.3.1 Crearea unui domeniu ENS pentru afaceri 29
6.3.2 Asocierea domeniului ENS cu un portofel 29
6.3.3 Reprezentarea entității de afaceri ca NFT 29
6.4 Ocean Protocol și Compute-to-Data 30
6.4.1 Introducere în Ocean Protocol 30
6.4.2 6.4.2 Compute-to-Data: O abordare care protejează confidențialitatea 30
6.4.3 Utilizarea Ocean Protocol pentru crearea activelor de date 30
6.5 Integrarea algoritmilor ca NFT-uri 30
6.5.1 NFT-uri pentru algoritmi: Introducere și beneficii 30
6.5.2 6.5.2 Dezvoltarea și reprezentarea algoritmilor 30
6.5.3 Executarea algoritmilor folosind Compute-to-Data 31
6.6 Centralizarea veniturilor și a proprietății intelectuale 31
6.6.1 Monetizare și redevențe prin NFT-uri 31
6.6.2 Gestionarea și protecția proprietății intelectuale 31
6.6.3 Creșterea colaborării și a valorii 31
Chapter 7 Performanța Energetică a Clădirilor Rezidențiale: Caz de Utilizare Web3 31
7.1 Introducere 31
7.2 Web3 și schimbul descentralizat de date 32
7.3 Context legislativ și standardizarea datelor 32
7.4 Procesarea și transformarea datelor 33
7.5 Dezvoltarea modelului de învățare automată 33
7.5.1 Criterii de selecție a modelului: 33
7.5.2 Interacțiunea utilizatorului și implementarea modelului 33
7.5.3 Procesul de predicție: 33
7.5.4 Exemplu de rezultate: 33
7.6 Publicarea pe platforme Web3 34
7.6.1 Integrarea Web3: 34
7.7 Caz de afaceri și potențialul viitor 34

7.7.1 Beneficii cheie: 34
7.7.2 Direcții viitoare: 34
Chapter 8 Predicții pentru NFL Fantasy Football – Studiu de caz 35
8.1 Introducere 35
8.2 Analiza datelor 35
8.3 Ingineria caracteristicilor 35
8.4 Construirea modelului 35
8.5 Valorificarea provocării de date pentru dezvoltarea modelului 36
8.6 Selectarea celui mai performant model 36
8.7 Predicțiile finale și implementarea 36
Chapter 9 Ocean Foam: Împuternicirea Oamenilor de Știință din Domeniul Datelor 37
9.1 Prezentare generală a Ocean Foam 37
9.2 Rolul Ocean Foam în inovație 37
9.3 Obiective și scopuri 37
9.4 Nevoia de Ocean Foam 37
9.5 Viziune și misiune 38
9.6 Valori fundamentale 38
9.7 Publicul țintă 38
9.8 Declarația problemă-oportunitate 38
9.9 Intrarea pe piață: imobiliare Web3 38
9.10 Strategia de creștere și proiecții financiare 39
9.11 Sumar 39
Chapter 10 Concluzii 40
10.1 Concluzii generale 40
10.2 10.2 Contribuții originale 40
10.3 Direcții viitoare de cercetare 41
10.3.1 Scalarea Ocean Foam 41
10.3.2 10.3.2 Extinderea către alte industrii 41
10.3.3 10.3.3 Implicarea comunității 41
10.3.4 10.3.4 Tehnologii emergente 41
Bibilografie 42

Chapter 1 Fundamentele Inteligenței Artificiale

1.1 Introducere

Acest capitol explorează conceptele fundamentale ale inteligenței artificiale, incluzând definiția, domeniul de aplicare, clasificările și componentele sale esențiale. De asemenea, analizează intersecția dintre inteligența artificială și tehnologiile emergente, precum Web3 și guvernanța descentralizată. În plus, capitolul abordează percepția publică, preocupările etice și peisajul actual al inteligenței artificiale, subliniind rolul principalilor actori din industrie și al instituțiilor academice în modelarea viitorului acesteia.

1.2 Definiția și Caracteristicile Fundamentale ale Inteligenței Artificiale

Inteligența artificială (IA) se referă la sistemele computaționale care imită funcții cognitive precum învățarea, luarea deciziilor și rezolvarea problemelor. Actul Național pentru Inițiativa privind Inteligența din 2020 definește IA ca fiind sisteme bazate pe mașini care fac predicții, oferă recomandări sau iau decizii care influențează atât mediile reale, cât și cele virtuale.

1.2.1 Caracteristici cheie ale sistemelor de inteligență artificială

Sistemele de IA prezintă, în general, următoarele caracteristici:

- Percepție: IA poate procesa informații senzoriale, precum imagini, sunet și date din mediu.
- Învățare: Învățarea automată (ML) permite IA să își îmbunătățească performanțele pe baza modelelor de date.
- Raționament și luarea deciziilor: IA aplică reguli logice pentru a analiza datele și a prezice rezultate.
- Rezolvarea problemelor: IA optimizează soluțiile pentru provocări complexe în logistică, medicină și analiză de afaceri.
- Procesarea limbajului natural (NLP): IA poate înțelege și genera limbaj uman, facilitând utilizarea chatbot-urilor și serviciilor de traducere.
- Adaptabilitate: IA se ajustează dinamic la noi medii, ceea ce este esențial pentru aplicații precum vehiculele autonome.
- AI dynamically adjusts to new environments, crucial for applications like autonomous vehicles.

1.3 Clasificările Inteligenței Artificiale

IA este clasificată în funcție de capacitățile și funcțiile sale, variind de la sisteme specializate la inteligență generală autonomă.

1.3.1 Inteligența Artificială Îngustă (IA Slabă)

IA îngustă se referă la sisteme concepute pentru sarcini specifice, precum recunoașterea facială, detectarea fraudei și asistenții vocali (ex. Siri, Alexa). Deși sunt foarte eficiente în domeniile desemnate, aceste sisteme nu pot generaliza cunoștințele dincolo de antrenamentul lor.

1.3.2 Inteligența Artificială Generală (AGI)

AGI, numită și IA Puternică, reprezintă un sistem teoretic capabil să efectueze orice sarcină intelectuală pe care o poate face un om. AGI ar trebui să demonstreze raționament, rezolvare de probleme și adaptabilitate în multiple domenii fără programare specifică. Cu toate acestea, AGI rămâne un obiectiv pe termen lung al cercetării în domeniul IA, deoarece niciun sistem actual nu prezintă inteligență asemănătoare celei umane.

1.3.3 Clasificarea funcțională a IA

IA poate fi clasificată și în funcție de funcționalitate:

- Mașini reactive: Sisteme simple care răspund la stimuli fără memorie (ex. Deep Blue de la IBM).
- IA cu memorie limitată: Sisteme care utilizează experiențele trecute pentru a lua decizii (ex. mașini autonome).
- IA cu Teoria Minții (Teoretică): Viitoarele sisteme IA capabile să înțeleagă emoțiile și intențiile umane.
- IA Autoconștientă (Teoretică): O IA ipotetică care posedă conștiință și autonomie, ridicând preocupări filosofice și etice.

1.4 Învățarea Automată vs. Învățarea Profundă

Învățarea automată și învățarea profundă sunt subdomenii esențiale ale IA care permit învățarea autonomă și recunoașterea modelelor.

1.4.1 Învățarea Automată (ML)

Învățarea automată implică algoritmi care permit sistemelor să învețe din date și să își îmbunătățească performanța. Se împarte în:

- Învățare supervizată: Algoritmi antrenați pe date etichetate (ex. detectarea spamului, scoruri de credit).
- Învățare nesupervizată: Algoritmi care identifică modele în date neetichetate (ex. segmentarea clienților).
- Învățare prin întărire: Sistemele IA învață prin încercare și eroare folosind recompense și penalizări (ex. IA pentru jocuri video).

1.4.2 Învățarea Profundă (DL)

Învățarea profundă, un subset al ML, utilizează rețele neuronale artificiale pentru a procesa cantități mari de date. Spre deosebire de ML tradițional, învățarea profundă extrage automat caracteristici din date brute, ceea ce o face foarte eficientă pentru recunoașterea imaginilor, procesarea vorbirii și luarea deciziilor complexe.

1.5 IA și Web3: Descentralizare și Autonomie

Web3 reprezintă următoarea etapă a internetului, caracterizată prin rețele descentralizate bazate pe tehnologia blockchain. Integrarea IA în Web3 oferă securitate sporită, transparență și suveranitate a utilizatorilor asupra datelor.

1.5.1 Sinergia dintre IA și Blockchain

- Schimbul descentralizat de date: Modelele IA pot fi antrenate pe piețe de date bazate pe blockchain, asigurând confidențialitatea și securitatea.
- Agenți IA autonomi: Contractele inteligente alimentate de IA optimizează aplicațiile de finanțe descentralizate (DeFi).
- IA care păstrează confidențialitatea: Tehnologii precum zero-knowledge proofs permit calcule IA fără a expune date sensibile.

1.5.2 IA în DAOs (Organizații Autonome Descentralizate)

IA poate îmbunătăți guvernanța DAO prin automatizarea luării deciziilor, alocării resurselor și proceselor de vot ale comunității.

1.6 Percepția Publică și Considerațiile Etice

Opiniile publicului asupra IA sunt influențate de reprezentările media, preocupările etice și aplicațiile din lumea reală.

1.6.1 IA în Cultura Populară

Media prezintă IA fie ca o tehnologie revoluționară, fie ca o amenințare distopică, influențând modul în care societatea percepe riscurile și beneficiile IA.

1.6.2 Confidențialitate, Bias și Transparență

- Confidențialitatea datelor: Colectarea masivă de date de către IA ridică probleme privind securitatea și supravegherea.
- Bias algoritmic: IA poate amplifica prejudecățile din seturile de date de antrenament, generând dileme etice.
- Transparența: Multe sisteme IA sunt „cutii negre", unde procesele decizionale nu sunt ușor interpretabile.

1.6.3 IA și Forța de Muncă

Automatizarea bazată pe inteligență artificială transformă industriile, iar proiecțiile indică faptul că milioane de locuri de muncă ar putea fi înlocuite de IA până în 2030. Deși IA creează, de asemenea, noi oportunități de angajare, recalificarea forței de muncă și politicile sociale sunt esențiale pentru a atenua impactul economic al acestei tranziții.

1.7 Mediul Inteligenței Artificiale: Industrie, Academie și Descentralizare

Dezvoltarea inteligenței artificiale este determinată de colaborarea dintre liderii din industrie, instituțiile de cercetare și ecosistemele emergente de IA descentralizată.

1.7.1 Liderii Tradiționali în IA

Principalele companii și instituții de cercetare care contribuie la avansul IA includ:

- Google DeepMind – Cercetare în învățarea prin întărire și aplicații IA în domeniul sănătății.
- Amazon AWS – Servicii IA bazate pe cloud.
- Microsoft & OpenAI – Dezvoltarea modelelor de IA generativă precum GPT-4.
- Meta AI Research – Aplicații IA în rețele sociale și metavers.

1.7.2 Platforme IA Descentralizate

Pe lângă giganții tehnologici, o serie de platforme blockchain contribuie la descentralizarea inteligenței artificiale:

- SingularityNET – O piață descentralizată pentru servicii de IA.
- Ocean Protocol – Partajare de date bazată pe blockchain pentru antrenarea modelelor IA.
- Fetch.AI – Automatizare bazată pe IA în rețele descentralizate.

1.7.3 IA și Geopolitica

Guvernele din întreaga lume concurează pentru supremația în domeniul IA:

- China – Investiții masive pentru a atinge poziția de lider mondial în IA până în 2030.
- Statele Unite – Progres determinat de inovația sectorului privat.
- Uniunea Europeană – Reglementarea IA cu accent pe etică și responsabilitate (ex. AI Act).

Chapter 2 Protocolul de Schimb de Date Descentralizat

2.1 Introducere

Industria producției generează cantități vaste de date provenite din senzori, mașini și alte surse, având potențialul de a îmbunătăți eficiența, de a reduce costurile și de a optimiza lanțurile de aprovizionare. Totuși, provocările legate de securitatea datelor, confidențialitate și transparență împiedică schimbul fluid de informații. Metodele tradiționale de schimb de date centralizate expun părțile implicate la riscuri precum accesul neautorizat, manipularea datelor și atacurile cibernetice, limitând colaborarea și inovația.

Pentru a aborda aceste probleme, acest capitol propune un protocol de schimb de date descentralizat, bazat pe tehnologia blockchain, contracte inteligente, tokenizare și interoperabilitate, facilitând tranzacții de date sigure și transparente. Protocolul propus permite producătorilor să partajeze, să monetizeze și să utilizeze datele, păstrând în același timp confidențialitatea și asigurând conformitatea cu reglementările. Capitolul oferă o prezentare tehnică a protocolului și a aplicațiilor sale în ecosistemele industriale, evidențiind potențialul său de a revoluționa producția bazată pe date.

2.2 Context: Nevoia unui Schimb de Date Securizat în Producție

Datele joacă un rol critic în producția modernă, permițând întreținerea predictivă, optimizarea proceselor și luarea deciziilor bazate pe inteligență artificială. Analiza datelor istorice și în timp real ajută producătorii să identifice ineficiențele, să aloce resursele mai bine și să crească productivitatea. Cu toate acestea, reticența în partajarea datelor între organizații, din motive de securitate și concurență, a dus la pierderi de oportunități și ineficiență.

2.2.1 Provocările Schimbului Tradițional de Date

- Riscuri de securitate – Bazele de date centralizate sunt vulnerabile la atacuri cibernetice și acces neautorizat.
- Lipsa transparenței – Riscul de manipulare sau falsificare a datelor crește în absența unui sistem imuabil de înregistrare.
- Confidențialitate – Datele sensibile despre procesele de producție și designurile proprietare necesită control strict asupra accesului.
- Conformitate cu reglementările – Producătorii trebuie să respecte legi privind protecția datelor (ex. GDPR), ceea ce complică schimbul de date.

Un protocol de schimb de date descentralizat poate atenua aceste riscuri, oferind un sistem securizat și confidențial pentru tranzacțiile de date, fără a fi necesară o autoritate centrală.

2.3 Schimburile Descentralizate de Date: Principii și Beneficii

Pieţele descentralizate de date permit tranzacții de date între utilizatori prin contracte inteligente bazate pe blockchain, eliminând intermediarii și asigurând securitatea și transparența.

2.3.1 Cum Funcționează Schimburile Descentralizate de Date

- Contracte inteligente – Acorduri autoexecutabile pe blockchain care reglementează tranzacțiile de date.
- Monetizarea datelor – Stakeholderii pot tokeniza și vinde date în mod securizat.
- Interoperabilitate – Protocolul sprijină integrarea cu diferite sisteme de producție.
- Mecanisme de control al accesului – Tehnologii de confidențialitate permit partajarea controlată a datelor.

2.3.2 Avantajele unui Schimb de Date Descentralizat

- Securitate sporită – Datele sunt criptate și stocate pe blockchain, reducând riscurile de acces neautorizat.

- Proprietatea datelor – Participanții păstrează controlul asupra datelor și decid modul în care sunt partajate.
- Colaborare îmbunătățită – Accesul securizat și permisiunile gestionate permit colaborarea eficientă între producători, furnizori și dezvoltatori IA.
- Reducerea costurilor – Eliminarea intermediarilor reduce taxele și complexitatea administrativă.

2.4 Ocean Protocol: Un Cadru pentru Schimbul Descentralizat de Date

Ocean Protocol este o soluție bazată pe blockchain, concepută pentru a facilita schimbul de date securizat, confidențial și eficient. Acesta permite tokenizarea activelor de date, permițând organizațiilor să monetizeze și să controleze accesul la datele lor.

2.4.1 Caracteristici Cheie ale Ocean Protocol

- Contracte inteligente pentru tranzacțiile de date – Automatizează acordurile dintre furnizorii și consumatorii de date.
- Tokenizarea datelor (ERC-20 și ERC-721 NFT-uri) – Facilitează drepturile de proprietate și permisiunile de acces la seturile de date.
- Mecanismul Compute-to-Data – Permite antrenarea modelelor IA pe seturi de date private, fără a expune datele brute.
- Piețe descentralizate de date – Oferă un mediu securizat pentru publicarea, descoperirea și tranzacționarea seturilor de date.

2.4.2 Arhitectura Ocean Protocol

Ecosistemul Ocean este alcătuit din:

- Contracte inteligente – Facilitează tranzacțiile de date într-un mod securizat.
- Piețe Ocean – Platforme unde seturile de date pot fi publicate, descoperite și monetizate.
- Ocean.js & Ocean.py – Instrumente pentru dezvoltatori, utilizate în integrarea Ocean Protocol în aplicații.
- Servicii Compute-to-Data – Permit procesarea datelor de către algoritmi IA, menținând confidențialitatea.

2.4.3 NFT-uri de Date și Datatokens

Ocean Protocol introduce două active bazate pe blockchain:

- NFT-uri de date (ERC-721) – Reprezintă drepturile de proprietate intelectuală asupra unui set de date.

- Datatokens (ERC-20) – Acționează ca licențe pentru accesul la date.

Aceste active permit producătorilor să dețină propriile datele, oferind acces controlat prin contracte inteligente.

2.5 Acces Securizat la Date și Permisiuni

O provocare majoră în schimbul de date este asigurarea că doar entitățile autorizate pot accesa anumite seturi de date. Ocean Protocol oferă mecanisme de control granular al permisiunilor, permițând furnizorilor de date să stabilească condițiile de acces, modelele de preț și măsurile de securitate.

2.5.1 Controlul Accesului pe Bază de Roluri (RBAC)

RBAC asigură accesul doar pentru entitățile autorizate. Rolurile pot include:

- Producători (furnizori de date)
- Dezvoltatori IA (consumatori de date)
- Autorități de reglementare (verificarea conformității)

2.5.2 Tehnici de Protejare a Confidențialității

- Compute-to-Data – Permite antrenarea modelelor IA fără a expune datele brute.
- Zero-Knowledge Proofs (ZKP) – Permite verificarea tranzacțiilor de date fără a dezvălui informațiile conținute.
- Criptare omomorfă – Permite efectuarea calculelor pe date criptate.

Aceste tehnici oferă utilitate datelor, menținând în același timp confidențialitatea, permițând obținerea de informații bazate pe inteligență artificială fără a încălca confidențialitatea.

2.6 Construirea unei Piețe Descentralizate de Date

Dezvoltarea unui schimb descentralizat de date utilizând Ocean Protocol implică mai mulți pași esențiali pentru asigurarea unui mediu sigur, transparent și eficient pentru partajarea și monetizarea datelor.

2.6.1 Pașii pentru Implementarea unei Piețe de Date

- Înțelegerea Protocolului – Familiarizarea cu arhitectura și mecanismele contractelor inteligente Ocean Protocol.

- Definirea Sursei de Date – Identificarea dataset-urilor relevante pentru industrie (ex. date din senzori, analize ale lanțului de aprovizionare).
- Proiectarea Pieței de Date – Alegerea unui model de acces (public, privat sau bazat pe permisiuni).
- Implementarea Contractelor Inteligente – Crearea mecanismelor pentru gestionarea prețurilor, accesului tokenizat și guvernanței pieței.
- Publicarea Datelor – Încărcarea dataset-urilor cu metadate, condiții de acces și prețuri stabilite.
- Monitorizarea Tranzacțiilor – Utilizarea exploratoarelor blockchain pentru auditarea și urmărirea schimburilor de date.

2.6.2 Beneficiile Utilizării Ocean Protocol pentru o Piață de Date

- Descentralizare – Eliminarea dependenței de intermediari.
- Securitate – Criptarea datelor și stocarea sigură pe blockchain.
- Confidențialitate – Mecanismul Compute-to-Data permite analizarea datelor fără a le expune.
- Interoperabilitate – Integrarea cu diverse sisteme industriale și aplicații IA.

2.7 Compute-to-Data: Permiterea IA fără Expunerea Datelor

O inovație semnificativă în schimbul descentralizat de date este mecanismul Compute-to-Data, care permite modelelor IA să proceseze date fără a le accesa direct sau transfera.

2.7.1 Cum Funcționează Compute-to-Data

- Datele rămân la sursă – Modelele IA execută calcule pe dataset-uri fără a le muta.
- Procesare criptată – Algoritmii IA funcționează într-un mediu securizat, protejând datele sensibile.
- Partajarea rezultatelor, nu a datelor brute – Doar rezultatele finale sunt transmise utilizatorilor, minimizând riscurile de expunere.

2.7.2 Aplicații ale Compute-to-Data în Industrie

- Întreținere predictivă – Modelele IA analizează performanțele echipamentelor fără a expune datele despre producție.
- Optimizarea lanțului de aprovizionare – Analize descentralizate îmbunătățesc logistica și gestionarea stocurilor.
- Controlul calității – Algoritmii detectează defecte în produse fără a compromite datele sensibile despre procesele de fabricație.

Mecanismul Compute-to-Data oferă un echilibru ideal între utilitatea datelor și confidențialitate, permițând analiza descentralizată fără riscuri de securitate.

Chapter 3 Intersecția dintre Criptomonede, Blockchain și Sport

3.1 Introducere

Industria sportului trece printr-o transformare profundă datorită tehnologiilor digitale, în special blockchain și criptomonede. Acestea au devenit instrumente revoluționare în sport, oferind noi modele pentru interacțiunea fanilor, sponsorizări și tranzacții financiare.

- Blockchain este un registru descentralizat care asigură transparența și securitatea tranzacțiilor.
- Criptomonedele introduc active digitale care redefinesc valoarea, proprietatea și participarea în sport.

Împreună, aceste tehnologii îmbunătățesc implicarea fanilor, eficientizează tranzacțiile și creează noi modele financiare, precum fan tokens și NFT-uri (non-fungible tokens).

Acest capitol explorează sinergia dintre blockchain, criptomonede și sport, analizând suprapunerea demografică, implicațiile financiare și impactul strategic asupra industriei.

3.2 Sinergia dintre Blockchain și Sport

Industria sportului și tehnologia blockchain împărtășesc o aliniere demografică și tehnologică, în special în rândul generațiilor mai tinere, cum ar fi Millennials și Generația Z. Aceste categorii de public prezintă:

- Un nivel ridicat de alfabetizare digitală
- Deschidere către tehnologiile emergente
- Preferință pentru experiențe interactive și imersive

3.2.1 Suprapunerea Demografică

Adoptarea blockchain-ului în sport este determinată în mare măsură de comportamentele și interesele fanilor tineri:

- Există o suprapunere semnificativă între fanii criptomonedelor și fanii sportului, ambele comunități valorizând inovația digitală și descentralizarea.

- Fanii pasionați de tehnologie preferă colecționabile digitale, cum ar fi NFT-uri și fan tokens, care oferă un sentiment de proprietate și participare în viața echipei preferate.
- Experiențele digitale din sport, bazate pe blockchain, se aliniază cu tendințele din eSports și fantasy sports, unde activele digitale joacă un rol esențial.

Această aliniere a condus la parteneriate strategice între companiile de criptomonede și organizațiile sportive, incluzând:

- Acorduri de sponsorizare între firme de blockchain și ligi sportive majore.
- Tokenizarea fanilor, permițând suporterilor să se implice în deciziile echipei.
- Integrarea criptomonedelor în bilete, vânzări de produse și programe de loialitate.

3.2.2 Creșterea Fan Tokens și a Colecționabilelor Digitale

Fan tokens și NFT-urile au transformat modul în care fanii interacționează cu echipele lor preferate, oferindu-le drepturi de vot, acces exclusiv și active digitale tranzacționabile.

Beneficii pentru fani:

- Drepturi de vot – Deținătorii de tokeni pot influența decizii minore ale echipei, precum designul echipamentului sau melodia de sărbătorire a golurilor.
- Conținut exclusiv – Acces la filmări din culise, întâlniri cu jucătorii și experiențe VIP.
- Active digitale tranzacționabile – Fanii pot cumpăra, vinde și tranzacționa NFT-uri pe piețe blockchain.

Exemple:

- Paris Saint-Germain (PSG), Juventus și FC Barcelona au lansat fan tokens prin Socios.com, permițând fanilor să participe la deciziile clubului.
- NBA Top Shot le permite utilizatorilor să cumpere, vândă și dețină momente video oficial licențiate ale NBA sub formă de NFT-uri.

3.3 Blockchain și Criptomonede în Operațiunile Sportive

Blockchain și criptomonedele influențează industria sportivă în trei domenii majore:

- Plăți și tranzacții
- Tokenizarea activelor
- Contracte inteligente pentru sponsorizări și acorduri de jucători

3.3.1 Criptomonede ca Metodă de Plată

Echipele și organizațiile sportive au început să accepte criptomonede pentru:

- Bilete și produse sportive
- Acorduri de sponsorizare
- Salarii și bonusuri pentru jucători

Avantaje:

- Tranzacții rapide și sigure la nivel internațional, reducând costurile și întârzierile.
- Finanțare descentralizată (DeFi), oferind modele alternative de finanțare pentru cluburi sportive.
- Recompense și programe de loialitate bazate pe criptomonede, stimulând implicarea fanilor.

Exemplu:

- Dallas Mavericks și Sacramento Kings acceptă Bitcoin și Ethereum pentru achiziția de bilete și produse oficiale.

3.3.2 Tokenizarea în Sport

Blockchain permite tokenizarea activelor sportive, digitalizând:

- Drepturile de sponsorizare
- Biletele pentru meciuri
- Contractele jucătorilor
- Memorabilia sportivă și colecționabile digitale

Exemplu:

- Formula 1 și Crypto.com au semnat un parteneriat pentru integrarea plăților cripto și sponsorizărilor NFT în cursele de F1.

3.3.3 Contracte Inteligente în Sponsorizări și Acorduri de Jucători

Contractele inteligente sunt acorduri auto-executabile, care automatizează:

- Plățile de sponsorizare (ex. bonusuri eliberate când un sportiv atinge un obiectiv).

- Clauze contractuale pentru jucători (ex. creșteri automate de salariu pentru performanțe bune).
- Modele de partajare a veniturilor, asigurând o distribuție echitabilă între părți.

Exemplu:

- FC Barcelona utilizează contracte tokenizate pentru a eficientiza distribuția veniturilor din sponsorizări.

3.4 Impactul Blockchain asupra Sponsorizărilor și Parteneriatelor

3.4.1 Sponsorizările Criptografice în Sport

Acorduri notabile:

- Crypto.com a semnat un contract de 700 de milioane de dolari pentru drepturile de denumire a arenei Los Angeles Lakers.
- FTX a plătit 135 de milioane de dolari pentru redenumirea arenei Miami Heat.
- Tezos și Red Bull Racing au colaborat pentru a crea colecționabile digitale bazate pe blockchain.

3.5 Viitorul Blockchain în Sport

3.5.1 Bilete Inteligente și Măsuri Anti-Fraudă

- NFT-uri pentru bilete elimină falsificarea.
- Contractele inteligente reglementează revânzarea biletelor și previn speculațiile.

3.5.2 eSports și Ligi Fantastice Descentralizate

- Tokenizarea jucătorilor virtuali în fantasy sports.
- Payout-uri automate prin contracte inteligente.

3.5.3 Media Sportivă și Monetizarea Conținutului

- Microtranzacții pentru conținut exclusiv.
- Jucătorii își pot tokeniza conținutul digital pentru a genera venituri.

Chapter 4 Evoluția LLM-urilor în Academia

4.1 Introducere

Integrarea Large Language Models (LLMs), precum GPT-4, în mediul academic a transformat cercetarea și educația, oferind capacități puternice de generare, analiză și sinteză a textului. Cu toate acestea, deși LLM-urile îmbunătățesc eficiența și accesibilitatea, ele ridică și provocări etice, printre care:

- Bias-ul în conținutul generat de AI, care poate afecta obiectivitatea cercetării.
- Probleme de integritate academică, în special în diferențierea lucrărilor realizate de studenți față de cele generate de AI.

Acest capitol explorează aceste două provocări fundamentale printr-o abordare cantitativă și analitică, incluzând:

- Modele statistice pentru măsurarea bias-ului în cercetarea generată de LLM-uri.
- Analiză prin regresie logistică pentru a distingere între texte scrise de AI și cele redactate de studenți.
- Studii de caz ipotetice, care evidențiază implicațiile practice ale LLM-urilor în mediul academic.

Prin prezentarea oportunităților și riscurilor, acest capitol oferă cele mai bune practici și strategii de atenuare pentru integrarea etică a AI în instituțiile academice.

4.2 Evoluția LLM-urilor în Academia

4.2.1 De la Procesare de Text la Inteligență Contextuală

LLM-urile au evoluat de la instrumente de bază pentru procesarea textului la sisteme avansate de AI, capabile să înțeleagă și să genereze text coerent și contextual.

Dezvoltări cheie:

- Primele modele AI se bazau pe recunoașterea de tipare și clasificarea textului.
- Modelele de învățare profundă au introdus conștientizarea contextului în generarea de text.
- Arhitecturi bazate pe transformere (ex. GPT-4, BERT) au permis înțelegerea limbajului la un nivel fără precedent.

Aceste progrese au făcut ca LLM-urile să devină indispensabile în cercetarea academică și metodologia predării.

4.2.2 Impactul asupra Cercetării și Educației

Aplicații în Cercetare:

- Revizuire automată a literaturii – LLM-urile ajută la rezumarea și analizarea unor volume mari de studii.
- Generarea de ipoteze – Modelele AI sugerează întrebări și metodologii pentru cercetare.
- Sinteză de date – LLM-urile integrează perspective interdisciplinare, fiind utile în științele sociale, lingvistică și cercetarea cognitivă.

Aplicații în Educație:

- Sisteme de tutorat bazate pe AI, care personalizează experiențele de învățare.
- Instrumente educaționale interactive, care îmbunătățesc învățarea limbajelor străine și simulările academice.

Deși aceste aplicații îmbunătățesc productivitatea, ele ridică probleme legate de bias, confidențialitatea datelor și considerații etice.

4.3 Provocări Etice în Utilizarea LLM-urilor în Academia

4.3.1 Bias-ul în Cercetarea Generată de AI

Una dintre cele mai mari probleme ale utilizării AI în mediul academic este bias-ul încorporat în datele de antrenare ale LLM-urilor. Aceste tendințe nedorite provin din influențe istorice, culturale și sociale prezente în seturile de date folosite pentru antrenarea modelelor.

Dacă nu este corectat, bias-ul poate:

- Distorsiona rezultatele cercetării, favorizând anumite perspective.
- Perpetua stereotipuri, în special în științele sociale, istorie și politici publice.
- Influența conținutul educațional, ducând la curricule părtinitoare și interpretări eronate ale realității.

Exemplu**:**

- Dacă un LLM este utilizat pentru a studia reprezentarea de gen în media, bias-urile preexistente în seturile de date pot genera concluzii eronate, care întăresc stereotipurile.

4.3.2 Integritatea Academică și Plagiatul

LLM-urile șterg granița dintre conținutul generat de oameni și cel generat de AI, ceea ce ridică probleme precum:

- Atribuirea autorului – cum determinăm dacă un student a scris independent o lucrare?
- Plagiatul generat de AI – studenții pot folosi LLM-uri pentru a produce conținut fără citare corespunzătoare.
- Supra-dependența de AI, care diminuează gândirea critică și abilitățile de cercetare originale.

4.4 Abordarea Bias-ului în Cercetarea Asistată de LLM-uri

Pentru a asigura obiectivitatea cercetării, instituțiile academice trebuie să implementeze strategii de detectare și atenuare a bias-ului.

4.4.1 Studiu de Caz: Măsurarea Bias-ului în Output-urile LLM-urilor

O echipă de cercetători universitari a utilizat un LLM pentru a analiza comportamente sociale din diverse surse (social media, jurnale academice, texte istorice).

Rezultatele analizei statistice au arătat bias-uri de gen și rasiale în output-urile AI.

Pentru măsurarea acestora, s-au folosit:

- Calcularea abaterii standard (σ)
- Coeficientul de variație (CV)

4.4.2 Strategii de Reducere a Bias-ului

- Training în etica AI – implementarea de cursuri obligatorii de etică AI pentru cercetători.
- Cadrul de evaluare a bias-ului – realizarea de audituri etice în diferite faze ale cercetării.
- Date de antrenare diverse – extinderea seturilor de date pentru a include surse mai variate.

Prin analize cantitative și reforme instituționale, universitățile pot reduce bias-ul AI și menține integritatea cercetării.

4.5 Integritatea Academică în Era Scrierii Asistate de AI

Pentru a combate plagiatul generat de AI, instituțiile dezvoltă modele de detecție bazate pe învățare automată.

4.5.1 Model de Regresie Logistică pentru Detectarea AI

Un model de regresie logistică este antrenat pentru a clasifica textele ca fiind:

- Scrise de studenți (0)
- Generate de AI (1)

Criterii utilizate:

- Complexitatea textului (ex. lungimea frazelor, dificultatea cuvintelor).
- Diversitatea vocabularului (ex. coeficientul Type-Token).
- Variația sintactică (ex. complexitatea structurii frazelor).

4.5.2 Evaluarea Performanței

- Matricea de confuzie – măsoară clasificările corecte și eronate.
- Analiza curbei ROC – evaluarea eficienței modelului de detecție.

4.5.3 Implicații Etice

- Detecția plagiatului AI trebuie să echilibreze supravegherea academică cu evaluarea corectă.
- Alfabetizarea AI trebuie încurajată, astfel încât studenții să înțeleagă limitele etice ale utilizării AI.

4.6 Considerații pentru Viitor

4.6.1 Consolidarea Ghidurilor Etice

- Definirea nivelurilor acceptabile de asistență AI în sarcinile academice.
- Standarde de citare pentru conținutul generat de AI.
- Măsuri disciplinare pentru utilizarea necorespunzătoare a AI.

Chapter 5 Învățarea Federată în Industria Farmaceutică

5.1 Introducere

The Industria farmaceutică se bazează pe volume mari de date provenite din cercetare, studii clinice și monitorizarea pacienților. Cu toate acestea, provocările legate de:

- Confidențialitatea datelor (reglementări precum GDPR, HIPAA).
- Riscuri de securitate cibernetică.
- Lipsa interoperabilității între diferite sisteme.
- Constrângerile de scalabilitate îngreunează utilizarea eficientă a acestor date.

Învățarea federată (Federated Learning - FL) oferă o abordare descentralizată a învățării automate, permițând antrenarea modelelor AI pe mai multe surse de date, fără a centraliza informațiile brute. Acest capitol explorează:

- Provocările gestionării datelor farmaceutice,
- Rolul învățării federate în dezvoltarea AI securizate,
- Strategii de implementare și aplicații viitoare.

5.2 Provocările Gestionării Datelor

5.2.1 Confidențialitatea Datelor și Conformitatea cu Reglementările

Legislația privind protecția datelor, precum GDPR (UE) și HIPAA (SUA), impune restricții stricte asupra colectării, stocării și prelucrării informațiilor despre pacienți.

Companiile farmaceutice trebuie să asigure:

- Criptarea și anonimizarea datelor pentru protejarea informațiilor sensibile.
- Jurnale de audit și gestionarea consimțământului pentru conformitate.

5.2.2 Securitatea Datelor și Amenințările Cibernetice

Datele farmaceutice sunt ținte principale pentru atacurile cibernetice, furtul de proprietate intelectuală și manipularea studiilor clinice.

Măsuri necesare:

- Criptare end-to-end a datelor stocate și transmise.
- Sisteme de detectare a intruziunilor și controale stricte de acces.

5.2.3 5.2.3 Integrarea și Interoperabilitatea Datelor

Cercetarea farmaceutică utilizează surse de date eterogene:

- Studii clinice,
- Dosare electronice ale pacienților (EHRs),
- Genomică,
- Evidențe din lumea reală (RWE - Real World Evidence).

Pentru a gestiona aceste date, sunt necesare:

- Standarde comune de schimb de date, precum CDISC și HL7.
- Tehnici avansate de armonizare a datelor.

5.2.4 Calitatea și Fiabilitatea Datelor

Datele de slabă calitate (erori, valori lipsă, bias-uri) compromit acuratețea modelelor AI.

Soluții:

- Validarea automată a datelor și curățarea acestora.
- Algoritmi de detectare și corectare a bias-ului pentru AI mai echitabil.

5.2.5 Scalabilitatea și Analiza Big Data

Descoperirea de medicamente și medicina personalizată necesită procesarea unor volume uriașe de date. Strategii:

- Calcul cloud și modele AI distribuite.
- Procesare paralelă pentru obținerea de insight-uri în timp real.

5.3 Învățarea Federată pentru Gestionarea Datelor

Învățarea federată oferă o soluție AI care protejează confidențialitatea datelor, permițând antrenarea modelelor fără a centraliza datele.

5.3.1 Cum Funcționează Învățarea Federată?

Spre deosebire de modelele AI tradiționale care adună datele într-un server central, învățarea federată permite antrenarea modelelor AI direct pe dispozitive locale, partajând doar actualizări ale modelului, nu date brute.

Mecanisme cheie:

- Agregare descentralizată a modelelor (fără transferul datelor).
- Calcul multi-party securizat (SMPC) pentru protecția informațiilor.

5.3.2 Avantaje Cheie

- Confidențialitate & Conformitate: respectă regulile GDPR/HIPAA.
- Scalabilitate: permite procesarea eficientă a seturilor mari de date distribuite.
- AI Colaborativ: îmbunătățește modelele predictive prin acces la date din multiple instituții.

5.4 Implementarea Învățării Federate

5.4.1 Infrastructura și Securitatea

Un sistem eficient de învățare federată necesită:

- Infrastructură cloud pentru procesarea AI distribuită.
- Criptare omomorfă și confidențialitate diferențială pentru protecția actualizărilor modelului.

5.4.2 5.4.2 Conformitatea Reglementărilor și Aspecte Etice

- Guvernanță transparentă a AI, pentru asigurarea respectării legislației.
- Colaborare cu autoritățile de reglementare pentru conformitatea cu noile legi privind protecția datelor.

5.4.3 Direcții de Cercetare Viitoare

- Farmacovigilență în timp real (monitorizarea siguranței medicamentelor).
- Medicină personalizată asistată de AI.
- Management descentralizat al studiilor clinice.

5.5 Compute-to-Data: Un Cadru pentru Protejarea Confidențialității

Pentru a îmbunătăți învățarea federată, Ocean Protocol introduce mecanismul Compute-to-Data, care permite:

- Executarea de calcule AI pe date descentralizate.
- Partajarea doar a rezultatelor antrenării modelului, nu a datelor brute.
- Piețe de date descentralizate pentru cercetare farmaceutică.

5.6 Abordarea Riscurilor și Provocărilor

5.6.1 Eterogenitatea Datelor și Bias-ul

Datele colectate din surse diferite pot avea calitate, structură și reprezentativitate variabile.

- Tehnici de normalizare a datelor pentru standardizare.
- Algoritmi de detectare și corectare a bias-ului.

5.6.2 Securitate și Confidențialitate

Protejarea sistemelor de învățare federată necesită:

- Protocoale de comunicare securizată pentru prevenirea atacurilor cibernetice.
- Agregare criptată a modelelor pentru prevenirea accesului neautorizat.

5.6.3 Etică și Guvernanță IA

- Ghiduri de etică AI pentru utilizare responsabilă.
- Validare continuă a modelelor pentru transparență și echitate.

Chapter 6 Domenii ENS și NFT-uri pentru Entități de Afaceri Integrate

6.1 Introducere

Identitățile digitale sunt esențiale pentru afaceri, iar soluțiile bazate pe blockchain, cum ar fi domeniile Ethereum Name Service (ENS) și tokenurile nefungibile (NFT), oferă o metodă inovatoare de gestionare a acestora. Acest capitol explorează modul în care domeniile ENS, NFT-urile și funcționalitatea Compute-to-Data din Ocean Protocol colaborează pentru a îmbunătăți gestionarea activelor digitale.

Domeniile ENS simplifică administrarea activelor prin asocierea unor nume ușor de citit cu adresele Ethereum, consolidând identitatea de afaceri, veniturile și proprietatea intelectuală într-un singur portofel. NFT-urile oferă dovada deținerii și autenticității, facilitând tranzacțiile sigure și urmărirea eficientă a activelor. În plus, tokenizarea algoritmilor introduce o nouă metodă de gestionare și monetizare a proprietății intelectuale prin stocarea NFT-urilor de algoritmi alături de NFT-urile entităților de afaceri într-un singur portofel.

6.2 Domenii ENS și NFT-uri

Domeniile ENS înlocuiesc adresele complexe Ethereum cu nume ușor de reținut, făcând interacțiunile mai intuitive. Prin asocierea domeniilor ENS cu NFT-uri, companiile pot stabili identități digitale unice, asigurând autenticitatea și securitatea. Această integrare simplifică proprietatea digitală și îmbunătățește accesibilitatea, permițând firmelor să gestioneze activele și proprietatea intelectuală într-un ecosistem descentralizat.

NFT-urile oferă dovada deținerii imuabile și facilitează tranzacțiile peer-to-peer. Fiind active digitale unice, acestea stabilesc proveniența și asigură drepturile de proprietate digitală. Prin legarea NFT-urilor de domeniile ENS, companiile pot simplifica verificarea identității și administrarea activelor, facilitând transferuri fără probleme și sporind încrederea pe piață.

6.3 Crearea unei entități de afaceri cu domenii ENS și NFT-uri

6.3.1 Crearea unui domeniu ENS pentru afaceri

Un domeniu ENS pentru afaceri oferă o identitate digitală descentralizată, înlocuind adresele hexazecimale lungi cu un nume ușor de recunoscut. Înregistrarea unui domeniu și asocierea acestuia cu un portofel creează o identitate verificabilă public, simplificând interacțiunile cu activele în rețelele blockchain.

6.3.2 Asocierea domeniului ENS cu un portofel

Companiile își pot conecta domeniul ENS la un portofel cripto, permițându-le să administreze NFT-uri, fluxuri de venituri și proprietatea intelectuală dintr-un singur punct de acces. Această integrare asigură urmărirea și controlul eficient al activelor digitale, consolidând în același timp securitatea dreptului de proprietate.

6.3.3 Reprezentarea entității de afaceri ca NFT

Tokenizarea unei entități de afaceri sub formă de NFT permite autentificarea și monetizarea proprietății intelectuale, a mărcii și a altor active digitale. Companiile pot încorpora metadate, termeni de licențiere și documentație legală în NFT-uri, creând un registru transparent și verificabil al proprietății.

6.4 Ocean Protocol și Compute-to-Data

6.4.1 Introducere în Ocean Protocol

Ocean Protocol este un cadru descentralizat de schimb de date care facilitează partajarea și monetizarea securizată a datelor. Bazat pe tehnologia blockchain, acesta oferă o piață pentru descoperirea și accesarea seturilor de date valoroase, menținând în același timp confidențialitatea și drepturile de proprietate.

6.4.2 6.4.2 Compute-to-Data: O abordare care protejează confidențialitatea

Compute-to-Data permite efectuarea de calcule pe date sensibile fără a expune informațiile brute. Prin menținerea datelor în mediul lor original, această metodă asigură securitatea, permițând în același timp companiilor să genereze informații valoroase și să monetizeze activele de date. Afacerile care utilizează această funcționalitate pot efectua analize avansate, menținând un control strict al confidențialității.

6.4.3 Utilizarea Ocean Protocol pentru crearea activelor de date

Companiile pot tokeniza seturile de date ca NFT-uri, permițând verificarea proprietății și monetizarea acestora prin piața Ocean Protocol. Compute-to-Data permite companiilor să execute algoritmi pe datele tokenizate fără a compromite securitatea, sporind încrederea și extinzând oportunitățile de colaborare.

6.5 Integrarea algoritmilor ca NFT-uri

6.5.1 NFT-uri pentru algoritmi: Introducere și beneficii

Algoritmii pot fi tokenizați sub formă de NFT-uri, permițând dezvoltatorilor să își revendice dreptul de proprietate și să își monetizeze proprietatea intelectuală. NFT-urile pentru algoritmi oferă autenticitate verificabilă, facilitează licențierea și simplifică distribuirea algoritmilor prin piețele bazate pe blockchain.

6.5.2 6.5.2 Dezvoltarea și reprezentarea algoritmilor

Dezvoltatorii de algoritmi își pot tokeniza creațiile prin încorporarea metadatelor relevante, a detaliilor de licențiere și a restricțiilor de utilizare în NFT-uri. Această reprezentare asigură transparența și permite transferul fără probleme al dreptului de proprietate și al accesului în rețelele blockchain.

6.5.3 Executarea algoritmilor folosind Compute-to-Data

Compute-to-Data permite executarea algoritmilor pe seturi de date private fără a expune datele proprietare. Această abordare protejează proprietatea intelectuală, permițând în același timp cercetarea și analiza colaborativă. Dezvoltatorii de algoritmi își pot monetiza soluțiile oferind servicii de calcul securizate, care protejează confidențialitatea.

6.6 Centralizarea veniturilor și a proprietății intelectuale

6.6.1 Monetizare și redevențe prin NFT-uri

Prin tokenizarea activelor de afaceri și a algoritmilor, companiile pot genera venituri prin vânzări directe, acorduri de licențiere și distribuirea automată a redevențelor. Contractele inteligente integrate în NFT-uri facilitează plăți transparente și sigure, asigurând o monetizare continuă.

6.6.2 Gestionarea și protecția proprietății intelectuale

NFT-urile oferă o evidență imuabilă a dreptului de proprietate intelectuală, reducând riscul disputelor și utilizării neautorizate. Prin încorporarea termenilor de licențiere și a drepturilor de utilizare, companiile pot impune conformitatea și pot menține controlul asupra activelor lor digitale.

6.6.3 Creșterea colaborării și a valorii

Domeniile ENS, NFT-urile și Ocean Protocol creează un ecosistem colaborativ în care companiile, dezvoltatorii și furnizorii de date pot face schimb de resurse și expertiză. Prin integrarea NFT-urilor de algoritmi și date într-un singur cadru, afacerile pot crea soluții bazate pe date și pot accesa noi surse de venit.

Chapter 7 Performanța Energetică a Clădirilor Rezidențiale: Caz de Utilizare Web3

7.1 Introducere

Clădirile rezidențiale sunt responsabile pentru o parte semnificativă a consumului de energie și a emisiilor de gaze cu efect de seră. Îmbunătățirea eficienței energetice a acestora poate reduce emisiile, combate sărăcia energetică și stimula redresarea economică. Acest capitol explorează

modul în care învățarea automată și tehnologiile Web3, inclusiv blockchain, NFT-urile și contractele inteligente, pot fi utilizate pentru a îmbunătăți analiza performanței energetice a clădirilor și recomandările aferente.

Utilizând date din Registrul Certificatelor de Performanță Energetică din Scoția, a fost dezvoltat un model de învățare automată care oferă recomandări pentru modernizarea clădirilor. Setul de date și algoritmul au fost publicate pe Ocean Market, permițând accesul descentralizat, fără permisiuni, prin contracte inteligente. Acest caz de utilizare demonstrează cum aplicațiile AI bazate pe blockchain pot transforma datele guvernamentale în informații utile pentru public, promovând eficiența energetică și sustenabilitatea.

7.2 Web3 și schimbul descentralizat de date

Web3 permite gestionarea descentralizată a datelor prin tehnologia blockchain, eliminând nevoia de intermediari. Principalele caracteristici ale Web3 includ:

- Descentralizare: Datele și aplicațiile sunt distribuite într-o rețea peer-to-peer, în loc să fie stocate pe servere centralizate.
- Tranzacții pe blockchain: Contractele inteligente facilitează interacțiunile, asigurând transparență și imuabilitate.
- Portofele cripto și tokenuri: Utilizatorii accesează aplicațiile Web3 prin portofele precum MetaMask, care stochează tokenuri pentru plăți și verificarea identității.
- Compute-to-Data: Permite rularea modelelor de învățare automată pe seturi de date private, fără a expune datele brute, protejând confidențialitatea.

7.3 Context legislativ și standardizarea datelor

Directiva UE privind performanța energetică a clădirilor (EPBD) impune îmbunătățirea eficienței energetice a clădirilor. Strategia "Renovation Wave" a Comisiei Europene își propune să dubleze rata de renovare, îmbunătățind eficiența energetică și creând locuri de muncă. Eforturile de standardizare, conduse de EPB Center, includ standarde ISO precum:

- ISO 52000-1: Cadrul general pentru evaluarea performanței energetice a clădirilor.
- ISO 52016-1: Metode de calcul pentru necesarul de încălzire și răcire.
- ISO 52018-1: Indicatori de performanță pentru anvelopa clădirii eficiente energetic.

7.4 Procesarea și transformarea datelor

Setul de date utilizat în acest proiect provine din Registrul Certificatelor de Performanță Energetică din Scoția și include informații detaliate despre eficiența energetică a clădirilor rezidențiale. Datele au fost curățate și preprocesate pentru a asigura coerența și utilizabilitatea lor în modelul de învățare automată.

7.5 Dezvoltarea modelului de învățare automată

Pentru acest proiect a fost ales un model de arbore decizional, datorită caracteristicilor datelor și interpretabilității sale. Alte modele, precum regresia logistică, pădurile aleatorii și mașinile de suport vectorial (SVM), au fost luate în considerare, însă arborii de decizie au fost selectați pentru că gestionează eficient datele categorice.

7.5.1 Criterii de selecție a modelului:

- Abordare supravegheată: Deoarece setul de date este etichetat, a fost necesar un model de clasificare.
- Avantajele arborilor de decizie: Ușor de interpretat, gestionează bine datele non-liniare și oferă reguli de decizie clare.
- Antrenare și validare: Modelul a fost antrenat pe 900 de înregistrări și testat pe 101 înregistrări, obținând o precizie ridicată în prezicerea îmbunătățirilor de eficiență energetică.

7.5.2 Interacțiunea utilizatorului și implementarea modelului

Pentru a face modelul accesibil publicului, a fost dezvoltat un mecanism de intrare compatibil cu Web3. Utilizatorii pot introduce caracteristicile clădirii printr-o interfață de tip dropdown, iar sistemul generează recomandări pentru modernizare, bazate pe modelul antrenat.

7.5.3 Procesul de predicție:

- Utilizatorii selectează atributele clădirii dintr-un meniu predefinit.
- Sistemul encodează intrarea și o integrează în setul de date.
- Modelul rulează predicțiile și generează recomandările de eficiență energetică.
- Utilizatorii primesc o listă cu îmbunătățiri sugerate, împreună cu scorurile de încredere.

7.5.4 Exemplu de rezultate:

- Actualizare la izolație de perete dublu: 100% probabilitate

- Instalare panouri solare (2,5 kWp): 97,6% probabilitate
- Înlocuire ferestre cu geam simplu cu ferestre termopan: 100% probabilitate

7.6 Publicarea pe platforme Web3

Setul de date și modelul antrenat au fost publicate pe Ocean Market, permițând accesul descentralizat prin contracte inteligente bazate pe blockchain.

7.6.1 Integrarea Web3:

- Publicarea setului de date: Datele rămân criptate, accesibile doar prin Compute-to-Data.
- Publicarea algoritmului: Utilizatorii pot rula modelul de predicție pe setul de date fără a descărca datele brute.
- Tranzacții cu contracte inteligente: Accesul la seturi de date și modele este reglementat prin tranzacții MetaMask, asigurând transparență.
- Dovada deținerii prin NFT-uri: La publicare, este emis un NFT ca dovadă a proprietății, permițând monetizarea.

7.7 Caz de afaceri și potențialul viitor

Acest caz de utilizare Web3 demonstrează un model viabil pentru utilizarea combinată a blockchain-ului și AI în analiza datelor publice. Natura descentralizată a proiectului elimină dependența de instituții centralizate, facilitând în același timp monetizarea.

7.7.1 Beneficii cheie:

- Acces democratizat: Oricine poate analiza performanța energetică a clădirilor fără a necesita expertiză specializată.
- Monetizare automată: Publicatorii seturilor de date și algoritmilor pot percepe taxe prin contracte inteligente.
- Scalabilitate: Cadrul poate fi extins la alte seturi de date și industrii.

7.7.2 Direcții viitoare:

- Dezvoltarea unei interfețe Web3 prietenoase cu utilizatorii.
- Extinderea la seturi de date suplimentare despre eficiența energetică.
- Integrarea cu date de consum energetic în timp real pentru recomandări dinamice.

Chapter 8 Predicții pentru NFL Fantasy Football – Studiu de caz

8.1 Introducere

NFL Fantasy Football a evoluat într-un joc competitiv bazat pe strategie, unde predicțiile precise ale performanței jucătorilor sunt esențiale. Acest capitol prezintă un model care integrează tehnologia blockchain și învățarea automată pentru a prezice punctele jucătorilor NFL pentru sezonul 2023. Folosind date de la Pharaoh Analytics, studiul include analiza datelor, ingineria caracteristicilor, antrenarea și evaluarea modelului.

8.2 Analiza datelor

Analiza exploratorie a datelor (EDA) a fost efectuată pentru a înțelege setul de date, a identifica valori lipsă, valori aberante și a extrage informații pentru selecția caracteristicilor.

- Prezentarea setului de date – include statistici de performanță ale jucătorilor NFL de-a lungul mai multor sezoane
- Rezumat statistic – s-au calculat media, mediana și abaterea standard pentru indicatori cheie precum yarzi câștigați, touchdown-uri și puncte fantasy
- Valori lipsă și valori aberante – s-au aplicat tehnici de curățare a datelor, inclusiv imputare și detectare a anomaliilor
- Analiza corelației – s-au utilizat diagrame de căldură și grafice de dispersie pentru a identifica relațiile dintre caracteristici și punctele fantasy

8.3 Ingineria caracteristicilor

Selecția, transformarea și crearea caracteristicilor au fost realizate pentru a îmbunătăți acuratețea modelului.

- Selecția caracteristicilor – s-au prioritizat indicatorii cheie de performanță, precum touchdown-uri și recepții, pe baza corelației și cunoștințelor domeniului
- Transformarea caracteristicilor – s-au aplicat tehnici de normalizare și codificare pentru a asigura compatibilitatea cu modelele de învățare automată
- Crearea caracteristicilor – s-au introdus medii mobile, indicatori de eficiență și istoricul accidentărilor pentru a îmbunătăți predicțiile

8.4 Construirea modelului

Au fost evaluate mai multe modele de învățare automată pentru a determina cea mai bună abordare.

- **Se**lecția modelului – s-au luat în considerare regresia liniară, pădurile aleatorii, boosting-ul gradient și rețelele neuronale
- Antrenarea modelului – s-au aplicat ajustări de hiperparametri și validare încrucișată pentru a optimiza performanța
- Metrici de evaluare – s-au utilizat RMSE, MAE și coeficientul de determinare (R^2) pentru a măsura acuratețea

8.5 Valorificarea provocării de date pentru dezvoltarea modelului

O provocare de date utilizând datele Pharaoh Analytics a fost desfășurată prin platforma Desights a Ocean Protocol, implicând 350 de oameni de știință din domeniul datelor. Nouă participanți au trimis modele, iar un fond de premii de 5.000 USD a fost distribuit către primele trei soluții.

- Preprocesarea datelor – curățarea și transformarea a 4.600 de înregistrări din perioada 2016-2023
- Filtrarea jucătorilor și echipelor – concentrarea pe jucătorii activi din poziții ofensive cheie (QB, WR, TE, RB)
- Clustering – s-au creat grupuri de echipe și jucători pentru a normaliza metricele de performanță

8.6 Selectarea celui mai performant model

Au fost testate mai multe modele:

- Rețea neuronală – MAE de 42.2
- XGBoost – MAE de 41.8
- K-Nearest Neighbors – MAE de 42.0
- ElasticNet Regression – ales pentru echilibrul între acuratețe și interpretabilitate (MAE de 42.0)

8.7 Predicțiile finale și implementarea

Modelul final ElasticNet a fost antrenat pe întregul set de date și utilizat pentru a prezice punctele jucătorilor pentru sezonul 2023-2024. Rezultatele au fost compilate într-un fișier CSV pentru interpretare ușoară.

Chapter 9 Ocean Foam: Împuternicirea Oamenilor de Știință din Domeniul Datelor

9.1 Prezentare generală a Ocean Foam

Ocean Foam extinde programul de Provocări de Date al Ocean Protocol, facilitând colaborarea între oamenii de știință din domeniul datelor și antreprenori. Platforma permite monetizare continuă, protejarea proprietății intelectuale și integrare Web3, asigurând că informațiile, modelele și aplicațiile descentralizate (dApps) generează valoare pe termen lung.

9.2 Rolul Ocean Foam în inovație

Datele rămân subutilizate din cauza barierelor legate de acces, monetizare și colaborare. Ocean Foam abordează aceste provocări oferind un spațiu descentralizat unde oamenii de știință din domeniul datelor pot dezvolta, rafina și monetiza modele de învățare automată. Spre deosebire de competițiile tradiționale, care oferă premii unice, Ocean Foam creează fluxuri de venit recurente prin integrarea modelelor în dApps și licențiere.

9.3 Obiective și scopuri

Pentru oamenii de știință din domeniul datelor:

- Proprietatea asupra proprietății intelectuale – menținerea drepturilor asupra algoritmilor și modelelor dezvoltate
- Monetizare continuă – obținerea de venituri recurente prin integrarea și licențierea modelelor
- Libertate creativă – dezvoltarea de soluții independente de constrângerile instituționale

Pentru antreprenori:

- Informații de business – transformarea datelor brute în informații acționabile
- Acces la experți – conectarea cu oameni de știință din domeniul datelor de top
- Scalabilitate – utilizarea modelelor predictive gata de implementare

9.4 Nevoia de Ocean Foam

Industria necesită platforme care să deblocheze întregul potențial al datelor. Ocean Foam oferă:

- Acces la date – un depozit de seturi de date valoroase
- Căi de monetizare – venituri recurente pentru creatorii de algoritmi

- Schimb de date securizat – colaborare bazată pe încredere prin tehnologia blockchain

9.5 Viziune și misiune

Ocean Foam își propune să creeze un ecosistem deschis și descentralizat care sprijină inovația și antreprenoriatul, oferind instrumente sigure, colaborative și profitabile pentru utilizarea datelor.

9.6 Valori fundamentale

- Inovație – susținerea de noi soluții bazate pe date și modele de monetizare descentralizată
- Transparență – asigurarea unor tranzacții verificabile și a unei guvernări descentralizate
- Confidențialitate – implementarea Compute-to-Data pentru analize sigure
- Colaborare – încurajarea rezolvării problemelor în comunitate
- Protecția proprietății intelectuale – garantarea drepturilor asupra modelelor și a compensației echitabile

9.7 Publicul țintă

- Primar: oameni de știință din domeniul datelor și antreprenori Web3 care doresc să monetizeze modele sau să integreze aplicații bazate pe date
- Secundar: instituții academice și IMM-uri care caută soluții analitice scalabile

9.8 Declarația problemă-oportunitate

Pentru oamenii de știință din domeniul datelor:

- Acces la seturi de date diverse
- Monetizare dincolo de premiile competițiilor
- Alinierea modelelor cu nevoile din lumea reală

Pentru antreprenori:

- Accesibilitate la resurse din domeniul științei datelor
- Implementare simplificată a modelelor
- Scalabilitate pentru analize predictive

9.9 Intrarea pe piață: imobiliare Web3

Prezentare generală a pieței:

- Sectorul imobiliar din Dubai se digitalizează rapid, cu tranzacții susținute de blockchain estimate până în 2025
- Analizele predictive sunt în creștere, 72% dintre investitori căutând instrumente avansate de prognoză

Peisajul competitiv:

- Platformele existente nu oferă analize predictive integrate cu blockchain
- Ocean Foam umple acest gol, combinând știința datelor, transparența și automatizarea

9.10 Strategia de creștere și proiecții financiare

Strategia de intrare:

- Parteneriate – colaborare cu firme imobiliare și organisme de reglementare
- Educație – demonstrarea rolului blockchain în evaluarea proprietăților
- Conformitate – alinierea cu inițiativele guvernamentale de transformare digitală

Surse de venit:

- Abonamente – planuri tarifare de la 50$ la 500$ pe lună
- Plată per raport – rapoarte de piață unice, între 10$ și 100$
- Funcționalități premium – modele predictive avansate și informații AI-driven

Proiecții de creștere:

- Anul 1 – 1.500-2.500 tranzacții, generând 500.000$-1,2M$
- Anul 2 – 2.500-5.000 tranzacții, atingând 1,2M$-2,4M$
- Anul 3 – 5.000-7.500 tranzacții, crescând veniturile la 2,4M$-3,6M$

9.11 Sumar

Ocean Foam combină știința datelor, blockchain-ul și aplicațiile descentralizate pentru a crea un ecosistem sustenabil. Intrarea sa pe piața imobiliară demonstrează potențialul său de a transforma industriile, oferind analize predictive, transparență și automatizare. Prin valorificarea principiilor Web3, Ocean Foam împuternicește oamenii de știință din domeniul datelor și antreprenorii să creeze soluții scalabile și monetizabile.

Chapter 10 Concluzii

10.1 Concluzii generale

Această lucrare a explorat integrarea inteligenței artificiale (AI) cu tehnologiile descentralizate, blockchain, modelele de limbaj de mari dimensiuni (LLMs) și învățarea federată. AI transformă industriile prin îmbunătățirea procesului decizional, asigurarea confidențialității datelor și optimizarea proceselor de business. Studiul a stabilit o înțelegere fundamentală a capacităților AI și a analizat aplicarea sa în ecosistemele descentralizate precum Ocean Protocol. Prin integrarea AI cu blockchain, industriile pot aborda problemele de confidențialitate a datelor și pot construi încredere în schimbul de date.

Principalele constatări includ rolul AI în modelarea predictivă, impactul său asupra industriei sporturilor și aplicarea sa în finanțele descentralizate. Studiile de caz au demonstrat eficiența AI în optimizarea eficienței energetice a clădirilor și îmbunătățirea predicțiilor pentru NFL Fantasy Football. În plus, introducerea Ocean Foam a evidențiat modul în care platformele descentralizate îi ajută pe oamenii de știință din domeniul datelor să colaboreze și să-și monetizeze munca. Cercetarea a examinat și implicațiile etice ale AI, subliniind necesitatea transparenței, guvernării și implementării responsabile.

În concluzie, impactul transformator al AI asupra afacerilor este evident în diverse sectoare. Cu toate acestea, implementarea etică și stabilirea unor cadre de guvernare vor fi esențiale pentru inovare sustenabilă. Pe măsură ce AI continuă să evolueze, industriile trebuie să abordeze problemele legate de securitatea datelor, părtinirea algoritmică și responsabilitatea pentru a maximiza beneficiile și a minimiza riscurile.

10.2 10.2 Contribuții originale

- Integrarea AI și blockchain în industria sportului, concentrându-se pe diversificarea veniturilor și implicarea fanilor
- Analiza statistică a performanței jucătorilor NFL pe parcursul a opt ani, identificând modelul Linear (ElasticNet) drept cel mai precis predictor al punctelor fantasy
- Propunerea unui protocol descentralizat de schimb de date pentru sectorul producției utilizând blockchain și contracte inteligente
- Dezvoltarea unui cadru de învățare federată pentru antrenarea sigură a modelelor AI pe surse de date distribuite

- Introducerea unui model de regresie logistică pentru a diferenția conținutul generat de AI de cel creat de oameni, promovând utilizarea responsabilă a AI în cercetare
- Explorarea domeniilor ENS și NFT-urilor ca instrumente pentru gestionarea activelor digitale, îmbunătățind identitatea și monetizarea afacerilor
- Crearea unui algoritm AI pentru îmbunătățirea eficienței energetice a clădirilor, utilizând date guvernamentale deschise
- Lansarea Ocean Foam, o platformă Web3 care sprijină colaborarea oamenilor de știință din domeniul datelor, monetizarea modelelor și protejarea drepturilor de proprietate intelectuală

10.3 Direcții viitoare de cercetare

10.3.1 Scalarea Ocean Foam

Extinderea Ocean Foam necesită îmbunătățirea infrastructurii, rafinarea interfeței utilizatorului și integrarea stocării cloud pentru scalabilitate. Creșterea capacității de calcul va permite suportul unor modele AI mai complexe și analize în timp real. Optimizarea experienței utilizatorului prin instrumente AI de asistență și resurse pentru onboarding va facilita adoptarea mai largă a platformei.

10.3.2 10.3.2 Extinderea către alte industrii

Ocean Foam va viza domeniile energiei, agriculturii și orașelor inteligente, unde soluțiile descentralizate bazate pe date pot îmbunătăți eficiența. Analiza predictivă poate optimiza rețelele de energie, crește productivitatea agricolă și îmbunătăți planificarea urbană. Expansiunea geografică se va concentra pe piețele emergente.

10.3.3 10.3.3 Implicarea comunității

Construirea unui ecosistem colaborativ prin hackathoane, contribuții open-source și inițiative educaționale va consolida implicarea utilizatorilor. Încurajarea schimbului de cunoștințe și rezolvarea problemelor din lumea reală va accelera inovația și creșterea platformei.

10.3.4 10.3.4 Tehnologii emergente

Avansurile în AI, calculul cuantic și integrarea DeFi vor modela viitorul platformelor descentralizate de date. Calculul cuantic va permite procesări mai rapide, iar stimulentele bazate pe tokenuri vor crea noi oportunități de monetizare. Ocean Foam va rămâne în avangarda acestor schimbări tehnologice, asigurând inovare continuă în aplicațiile AI descentralizate.

Bibilografie

[1] I. H. Sarker, “AI-Based Modeling: Techniques, Applications and Research Issues Towards Automation, Intelligent and Smart Systems,” *SN COMPUT. SCI.*, vol. 3, no. 2, p. 158, Feb. 2022, doi: 10.1007/s42979-022-01043-x.

[2] “The National Artificial Intelligence Initiative (NAII),” National Artificial Intelligence Initiative. Accessed: May 30, 2022. [Online]. Available: https://www.ai.gov/

[3] “4 types of AI (artificial intelligence) explained,” Enterprise AI. Accessed: Sep. 10, 2024. [Online]. Available: https://www.techtarget.com/searchenterpriseai/tip/4-main-types-of-AI-explained

[4] “What is Artificial General Intelligence? - TechTarget,” SearchEnterpriseAI. Accessed: May 31, 2022. [Online]. Available: https://www.techtarget.com/searchenterpriseai/definition/artificial-general-intelligence-AGI

[5] B. Nancholas, “What are the different types of artificial intelligence?,” University of Wolverhampton. Accessed: Sep. 25, 2024. [Online]. Available: https://online.wlv.ac.uk/what-are-the-different-types-of-artificial-intelligence/

[6] “What Is Self-Aware AI? - Blue Goat Cyber.” Accessed: Sep. 25, 2024. [Online]. Available: https://bluegoatcyber.com/blog/what-is-self-aware-ai/

[7] SingularityNET, “A Deep Dive on the Differences Between Narrow AI and AGI,” SingularityNET. Accessed: Sep. 25, 2024. [Online]. Available: https://medium.com/singularitynet/a-deep-dive-on-the-differences-between-narrow-ai-and-agi-19016011c966

[8] L. Bunyaviroch and N. Thanyawet, *Review on AI Using Image Processing in The Medical Field*. 2021.

[9] “Discover the Differences Between AI vs. Machine Learning vs. Deep Learning [2022 Edition],” Simplilearn.com. Accessed: May 31, 2022. [Online]. Available: https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/ai-vs-machine-learning-vs-deep-learning

[10] S. Al-Janabi, M. Mohammad, and A. Al-Sultan, “A new method for prediction of air pollution based on intelligent computation,” *Soft Computing*, vol. 24, Jan. 2020, doi: 10.1007/s00500-019-04495-1.

[11] R. van Loon, “Machine learning explained: Understanding supervised, unsupervised, and reinforcement learning,” Big Data Made Simple. Accessed: May 31, 2022. [Online]. Available: https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/

[12] P. Deepan and L. R. Sudha, “Deep Learning Algorithm and Its Applications to IoT and Computer Vision,” in *Artificial Intelligence and IoT: Smart Convergence for Eco-friendly Topography*, K. G. Manoharan, J. A. Nehru, and S. Balasubramanian, Eds., Singapore: Springer, 2021, pp. 223–244. doi: 10.1007/978-981-33-6400-4_11.

[13] "AI vs. Machine Learning vs. Deep Learning: What's the Difference? | Built In." Accessed: May 31, 2022. [Online]. Available: https://builtin.com/artificial-intelligence/ai-vs-machine-learning

[14] info@lawtomated.com, "A.I. technical - Machine Learning vs. Deep Learning," lawtomated. Accessed: Sep. 11, 2024. [Online]. Available: https://lawtomated.com/a-i-technical-machine-vs-deep-learning/

[15] "What is Web3 and why is it important?," ethereum.org. Accessed: Dec. 12, 2022. [Online]. Available: https://ethereum.org

[16] "What are AI agents?," MIT Technology Review. Accessed: Sep. 25, 2024. [Online]. Available: https://www.technologyreview.com/2024/07/05/1094711/what-are-ai-agents/

[17] A. Ghavi, A. Qureshi, G. Weinstein, J. Schwartz, and S. Lofchie, "A Primer on DAOs," The Harvard Law School Forum on Corporate Governance. Accessed: Sep. 25, 2024. [Online]. Available: https://corpgov.law.harvard.edu/2022/09/17/a-primer-on-daos/

[18] P. Li, "Web3 Meets AI Marketplace: Exploring Opportunities, Analyzing Challenges, and Suggesting Solutions," Oct. 29, 2023, *arXiv*: arXiv:2310.19099. doi: 10.48550/arXiv.2310.19099.

[19] "Ipsos Global AI 2023 Report-WEB_0.pdf." Accessed: Sep. 25, 2024. [Online]. Available: https://www.ipsos.com/sites/default/files/ct/news/documents/2023-07/Ipsos%20Global%20AI%202023%20Report-WEB_0.pdf

[20] K. Nader, P. Toprac, S. Scott, and S. Baker, "Public understanding of artificial intelligence through entertainment media," *AI Soc*, pp. 1–14, Apr. 2022, doi: 10.1007/s00146-022-01427-w.

[21] "HAI_AI-Index-Report-2024_Chapter9.pdf." Accessed: Sep. 25, 2024. [Online]. Available: https://aiindex.stanford.edu/wp-content/uploads/2024/04/HAI_AI-Index-Report-2024_Chapter9.pdf

[22] B. Z. and A. Dafoe and C. for the G. of A. Oxford Future of Humanity Institute, University of, *6 High-level machine intelligence | Artificial Intelligence: American Attitudes and Trends*. Accessed: May 31, 2022. [Online]. Available: https://governanceai.github.io/US-Public-Opinion-Report-Jan-2019/high-level-machine-intelligence.html#subsecharmgood

[23] "What the future of work will mean for jobs, skills, and wages: Jobs lost, jobs gained | McKinsey." Accessed: May 31, 2022. [Online]. Available: https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages#part%203

[24] "AI, automation, and the future of work: Ten things to solve for (Tech4Good) | McKinsey." Accessed: Sep. 10, 2024. [Online]. Available: https://www.mckinsey.com/featured-insights/future-of-work/ai-automation-and-the-future-of-work-ten-things-to-solve-for

[25] "Unlocking Value in Manufacturing through Data Sharing," World Economic Forum. Accessed: Mar. 17, 2023. [Online]. Available: https://www.weforum.org/projects/data-sharing-for-manufacturing/

[26] "Top 10 Trends 2023." Accessed: Mar. 15, 2023. [Online]. Available: https://view.ceros.com/applied-intelligence/top-10-trends-2023

[27] "How big data can improve manufacturing | McKinsey." Accessed: Mar. 17, 2023. [Online]. Available: https://www.mckinsey.com/capabilities/operations/our-insights/how-big-data-can-improve-manufacturing

[28] "Big Data in manufacturing: Trends, tips, success stories," Software Development Company - N-iX. Accessed: Mar. 17, 2023. [Online]. Available: https://www.n-ix.com/big-data-in-manufacturing/

[29] R. A. R, "The scope of Decentralizing Data Marketplaces using blockchain," Accubits Blog. Accessed: Mar. 18, 2023. [Online]. Available: https://blog.accubits.com/the-scope-of-decentralizing-data-marketplaces-using-blockchain/

[30] "ERC-721." Accessed: Mar. 18, 2023. [Online]. Available: http://erc721.org/

[31] "ERC-20 Token Standard," ethereum.org. Accessed: Mar. 18, 2023. [Online]. Available: https://ethereum.org

[32] "Data NFTs and Datatokens." Accessed: Mar. 18, 2023. [Online]. Available: https://docs.oceanprotocol.com/core-concepts/datanft-and-datatoken

[33] "Decentralized Identifiers (DIDs) v1.0." Accessed: Mar. 18, 2023. [Online]. Available: https://w3c.github.io/did-core/

[34] "tech-whitepaper.pdf." Accessed: Aug. 20, 2024. [Online]. Available: https://oceanprotocol.com/tech-whitepaper.pdf

[35] "Architecture." Accessed: Mar. 18, 2023. [Online]. Available: https://docs.oceanprotocol.com/building-with-ocean/Compute-to-Data/Compute-to-Data-architecture

[36] "General Data Protection Regulation," *Wikipedia*. Mar. 13, 2023. Accessed: Mar. 18, 2023. [Online]. Available: https://en.wikipedia.org/w/index.php?title=General_Data_Protection_Regulation&oldid=1144398012

[37] "Role-based access control," *Wikipedia*. Feb. 13, 2023. Accessed: Mar. 18, 2023. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Role-based_access_control&oldid=1139093053

[38] Jamie, "Fine-Grained Permissions now supported in Ocean Protocol," Medium. Accessed: Mar. 18, 2023. [Online]. Available: https://blog.oceanprotocol.com/fine-grained-permissions-now-supported-in-ocean-protocol-4fe434af24b9

[39] "us-tmt-2022-sports-outlook.pdf." Accessed: Aug. 16, 2024. [Online]. Available: https://www2.deloitte.com/content/dam/Deloitte/us/Documents/technology-media-telecommunications/us-tmt-2022-sports-outlook.pdf

[40] PricewaterhouseCoopers, "Making sense of bitcoin, cryptocurrency and blockchain," PwC. Accessed: Aug. 16, 2024. [Online]. Available: https://www.pwc.com/us/en/industries/financial-services/fintech/bitcoin-blockchain-cryptocurrency.html

[41] "What is Blockchain and Artificial Intelligence (AI)? | IBM." Accessed: Aug. 16, 2024. [Online]. Available: https://www.ibm.com/topics/blockchain-ai

[42] "Sports Fans Are Into Cryptocurrency, and Brands Are Capitalizing." Accessed: Aug. 19, 2024. [Online]. Available: https://pro.morningconsult.com/articles/sports-fans-cryptocurrency-poll

[43] M. Takaoğlu and T. Dursun, "Decentralized Ledger Technologies in the Sports Industry: Applying NFT and Ordinal Theory for Athlete Data Management, Event Management, and Sports Collectibles," *Journal of Sports Industry & Blockchain Technology*, vol. 1, no. 1, Art. no. 1, Jul. 2024, doi: 10.5281/zenodo.12599668.

[44] "Crypto Adoption in Sports: Examining the Benefits and Challenges," Financial and Business News | Finance Magnates. Accessed: Aug. 16, 2024. [Online]. Available: https://www.financemagnates.com/cryptocurrency/innovation/crypto-adoption-in-sports-examining-the-benefits-and-challenges/

[45] A. Mendonça, "Blockchain Technology and Sports: The Impact of NFTs in the Sports Industry".

[46] A.-S. Berkani, H. Moumen, S. Benharzallah, S. Yahiaoui, and A. Bounceur, "Blockchain Use Cases in the Sports Industry: A Systematic Review," *Int J Netw Distrib Comput*, vol. 12, no. 1, pp. 17–40, Jun. 2024, doi: 10.1007/s44227-024-00022-3.

[47] T. Bason, P. Petratos, R. Porreca, and M. Mohiuddin Babu, "Sport and Blockchain," Jan. 2023.

[48] Crypto.com, "Crypto.com announced as official title partner of the Formula 1 Crypto.com Miami Grand Prix." Accessed: Aug. 16, 2024. [Online]. Available: https://crypto.com/company-news/crypto-com-announced-as-official-title-partner-of-the-formula-1-crypto-com-miami-grand-prix

[49] "FTX Fallout: How Sponsorship Partners are Moving Forward: Stinson LLP Law Firm." Accessed: Aug. 16, 2024. [Online]. Available: https://www.stinson.com/newsroom-publications-ftx-fallout-how-sponsorship-partners-are-moving-forward

[50] "Smart sports," MIT Technology Review. Accessed: Aug. 19, 2024. [Online]. Available: https://www.technologyreview.com/2021/01/29/1017028/smart-sports/

[51] J. Rankin and J. Emmett, "How Technology Is Redefining the Fan Experience at Sports and Music Venues," Gensler. Accessed: Aug. 19, 2024. [Online]. Available: https://www.gensler.com/blog/immersive-technology-is-redefining-the-sports-fan-experience

[52] J. C. Institute, "Embrace the Change: Benefits and Strategy of Web3 for Football Clubs," Johan Cruyff Institute. Accessed: Aug. 19, 2024. [Online]. Available: https://johancruyffinstitute.com/en/blog-en/embrace-the-change-benefits-and-strategy-of-web3-for-football-clubs/

[53] E. Glebova and P. Mihalova, "New currencies and new values in professional sports: blockchain, NFT, and fintech through the stakeholder approach," *JPES*, vol. 23, no. 5, pp. 1244–1252, Nay 2023.

[54] J. G. Meyer *et al.*, "ChatGPT and large language models in academia: opportunities and challenges," *BioData Mining*, vol. 16, no. 1, p. 20, Jul. 2023, doi: 10.1186/s13040-023-00339-9.

[55] M. Perkins, “Academic Integrity considerations of AI Large Language Models in the post-pandemic era: ChatGPT and beyond,” *Journal of University Teaching & Learning Practice*, vol. 20, no. 2, Feb. 2023, doi: 10.53761/1.20.02.07.

[56] L. De Angelis *et al.*, “ChatGPT and the rise of large language models: the new AI-driven infodemic threat in public health,” *Frontiers in Public Health*, vol. 11, 2023, Accessed: Nov. 13, 2023. [Online]. Available: https://www.frontiersin.org/articles/10.3389/fpubh.2023.1166120

[57] S. Porsdam Mann, B. D. Earp, N. Møller, S. Vynn, and J. Savulescu, “AUTOGEN: A Personalized Large Language Model for Academic Enhancement—Ethics and Proof of Principle,” *The American Journal of Bioethics*, vol. 23, no. 10, pp. 28–41, Oct. 2023, doi: 10.1080/15265161.2023.2233356.

[58] H. Li, J. T. Moon, S. Purkayastha, L. A. Celi, H. Trivedi, and J. W. Gichoya, “Ethics of large language models in medicine and medical research,” *The Lancet Digital Health*, vol. 5, no. 6, pp. e333–e335, Jun. 2023, doi: 10.1016/S2589-7500(23)00083-3.

[59] M. Hosseini and S. P. J. M. Horbach, “Fighting reviewer fatigue or amplifying bias? Considerations and recommendations for use of ChatGPT and other large language models in scholarly peer review,” *Res Integr Peer Rev*, vol. 8, no. 1, p. 4, May 2023, doi: 10.1186/s41073-023-00133-5.

[60] M. S. Orenstrakh, O. Karnalim, C. A. Suarez, and M. Liut, “Detecting LLM-Generated Text in Computing Education: A Comparative Study for ChatGPT Cases,” Jul. 10, 2023, *arXiv*: arXiv:2307.07411. doi: 10.48550/arXiv.2307.07411.

[61] Z. Liu, Z. Yao, F. Li, and B. Luo, “Check Me If You Can: Detecting ChatGPT-Generated Academic Writing using CheckGPT,” Jun. 07, 2023, *arXiv*: arXiv:2306.05524. doi: 10.48550/arXiv.2306.05524.

[62] “Getting started with logistic regression | Hex.” Accessed: Nov. 28, 2023. [Online]. Available: https://hex.techlogistic-regression

[63] “1.1. Linear Models,” scikit-learn. Accessed: Nov. 28, 2023. [Online]. Available: https://scikit-learn/stable/modules/linear_model.html

[64] “What is GDPR, the EU’s new data protection law?,” GDPR.eu. Accessed: May 22, 2023. [Online]. Available: https://gdpr.eu/what-is-gdpr/

[65] “Health Insurance Portability and Accountability Act of 1996 (HIPAA) | CDC.” Accessed: May 22, 2023. [Online]. Available: https://www.cdc.gov/phlp/publications/topic/hipaa.html

[66] N. Rieke, “What Is Federated Learning?,” NVIDIA Blog. Accessed: May 22, 2023. [Online]. Available: https://blogs.nvidia.com/blog/2019/10/13/what-is-federated-learning/

[67] “Top 7 Challenges Faced by Pharma AI,” Spiceworks. Accessed: Apr. 18, 2023. [Online]. Available: https://www.spiceworks.com/tech/artificial-intelligence/guest-article/top-challenges-faced-by-pharma-ai/

[68] “Standards.” Accessed: May 22, 2023. [Online]. Available: https://www.cdisc.org/standards

[69] “Introduction to HL7 Standards | HL7 International.” Accessed: May 22, 2023. [Online]. Available: https://www.hl7.org/implement/standards/index.cfm?ref=nav

[70] S. Dupré, “AI TRENDS & USE CASES IN THE PHARMACEUTICAL INDUSTRY,” Swiss Data Science Center. Accessed: Aug. 21, 2023. [Online]. Available: https://datascience.ch/ai-trends-use-cases-in-the-pharmaceutical-industry/

[71] “What is federated learning?,” IBM Research Blog. Accessed: May 22, 2023. [Online]. Available: https://research.ibm.com/blog/what-is-federated-learning

[72] K. Dasaradharami Reddy and T. R. Gadekallu, “A Comprehensive Survey on Federated Learning Techniques for Healthcare Informatics,” *Comput Intell Neurosci*, vol. 2023, p. 8393990, Mar. 2023, doi: 10.1155/2023/8393990.

[73] Y. Chen, F. Luo, T. Li, T. Xiang, Z. Liu, and J. Li, “A training-integrity privacy-preserving federated learning scheme with trusted execution environment,” *Information Sciences*, vol. 522, pp. 69–79, Jun. 2020, doi: 10.1016/j.ins.2020.02.037.

[74] S. Banabilah, M. Aloqaily, E. Alsayed, N. Malik, and Y. Jararweh, “Federated learning review: Fundamentals, enabling technologies, and future applications,” *Information Processing & Management*, vol. 59, no. 6, p. 103061, Nov. 2022, doi: 10.1016/j.ipm.2022.103061.

[75] **R. Maiorescu and A. Semenescu, “DECENTRALIZED DATA EXCHANGE PROTOCOL FOR THE MANUFACTURING INDUSTRY,” *Nonconventional Technologies Review*, vol. 27, no. 1, Art. no. 1, Mar. 2023, Accessed: May 22, 2023. [Online]. Available: http://www.revtn.ro/index.php/revtn/article/view/411**

[76] “tech-whitepaper.pdf.” Accessed: Aug. 21, 2023. [Online]. Available: https://oceanprotocol.com/tech-whitepaper.pdf

[77] “FELT Architecture.” Accessed: May 22, 2023. [Online]. Available: https://docs.feltlabs.ai/fundamentals/felt-architecture

[78] G. Georgiev, “What is ENS? Ethereum Name Service Explained (Updated 2022),” CryptoPotato. Accessed: May 31, 2023. [Online]. Available: https://cryptopotato.com/what-is-ens-ethereum-name-service/

[79] S. Kaczynski and S. D. Kominers, “How NFTs Create Value,” *Harvard Business Review*, Nov. 10, 2021. Accessed: Sep. 21, 2023. [Online]. Available: https://hbr.org/2021/11/how-nfts-create-value

[80] Maruf, “What is ENS? Ethereum Name Service in a Nutshell,” NFT Plazas. Accessed: May 30, 2023. [Online]. Available: https://nftplazas.com/what-is-ens-ethereum-name-service/

[81] “Chain Research – The Significance of ENS Domain Names and Their,” Chain. Accessed: May 31, 2023. [Online]. Available: https://www.chain.com/blog/ens-domain-names-and-their-use-cases

[82] brantly.eth, “Step-by-Step Guide to Importing a DNS Domain Name to ENS,” Medium. Accessed: May 31, 2023. [Online]. Available: https://medium.com/@brantly.eth/step-by-step-guide-to-importing-a-dns-domain-name-to-ens-d2d15feb03e8

[83] x, “The Role of ENS in Web3,” Web3 Domains^{SM}. Accessed: May 31, 2023. [Online]. Available: https://web3domains.com/the-role-of-ens-in-web3/

[84] “What is Ocean Protocol? (OCEAN) | Ocean Coin | Kraken.” Accessed: May 31, 2023. [Online]. Available: https://www.kraken.com/learn/what-is-ocean-protocol

[85] F. Benincasa, “The Rise of NFTs: Why Minting AI Algorithms is an Excellent Idea,” Smarter.ai. Accessed: May 31, 2023. [Online]. Available: https://medium.com/smarter-ai/the-rise-of-nfts-why-minting-ai-algorithms-is-an-excellent-idea-d401e07bacb0

[86] “Five legal considerations for businesses taking a lead on NFTs.” Accessed: May 31, 2023. [Online]. Available: https://www.ey.com/en_lu/tax/five-legal-considerations-for-businesses-taking-a-lead-on-nfts

[87] M. Madine, K. Salah, R. Jayaraman, Y. Al-Hammadi, J. Arshad, and I. Yaqoob, “appXchain: Application-Level Interoperability for Blockchain Networks,” *IEEE Access*, vol. 9, pp. 87777–87791, 2021, doi: 10.1109/ACCESS.2021.3089603.

[88] “Energy performance of buildings directive.” Accessed: Nov. 03, 2022. [Online]. Available: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/energy-performance-buildings-directive_en

[89] “EPC Data - March 2022 Extract - EPD Publication Note - Domestic Buildings - 2022Q1.pdf.”

[90] “statistics.gov.scot : Domestic Energy Performance Certificates - Dataset to Q3 2022.” Accessed: Dec. 12, 2022. [Online]. Available: https://statistics.gov.scot/data/domestic-energy-performance-certificates

[91] G. Edelman, “The Father of Web3 Wants You to Trust Less,” *Wired*. Accessed: Dec. 12, 2022. [Online]. Available: https://www.wired.com/story/web3-gavin-wood-interview/

[92] “What is Web 3 ? - And what you need to know to get started.” Accessed: Dec. 12, 2022. [Online]. Available: https://myraah.io/web3/whatisweb3

[93] “Web3,” *Wikipedia*. Dec. 12, 2022. Accessed: Dec. 12, 2022. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Web3&oldid=1126936341#cite_note-4

[94] P. Kim, “Understanding web3: The new version of the web that works on blockchain,” Business Insider. Accessed: Dec. 12, 2022. [Online]. Available: https://www.businessinsider.com/personal-finance/what-is-web3

[95] “An overview of Web3 wallet - Kyros Ventures.” Accessed: Dec. 12, 2022. [Online]. Available: https://blog.kyros.ventures/2022/08/18/an-overview-of-web3-wallet/

[96] “EUR-Lex - 52021PC0802 - EN - EUR-Lex.” Accessed: Dec. 13, 2022. [Online]. Available: https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX%3A52021PC0802

[97] “Implementing-the-EPBD_BPIE_2019.pdf.” Accessed: Sep. 17, 2024. [Online]. Available: https://bpie.eu/wp-content/uploads/2019/04/Implementing-the-EPBD_BPIE_2019.pdf

[98] “Renovation Wave,” European Commission - European Commission. Accessed: Dec. 12, 2022. [Online]. Available: https://ec.europa.eu/commission/presscorner/detail/en/IP_20_1835

[99] “BPIE is a leading independent centre of expertise on energy performance of buildings. > BPIE - Buildings Performance Institute Europe,” BPIE - Buildings Performance Institute Europe. Accessed: Sep. 17, 2024. [Online]. Available: https://www.bpie.eu/

[100] “The Energy Performance of Buildings Directive (EPBD) — EPB Standards — EPB Center | EPB Standards.” Accessed: Nov. 03, 2022. [Online]. Available: https://epb.center/epb-standards/energy-performance-buildings-directive-epbd/

[101] "— Documents — Support — EPB Center | EPB Standards." Accessed: Dec. 13, 2022. [Online]. Available: https://epb.center/support/documents/iso-52018-1/

[102] "Nearly zero-energy buildings | sosesg.com." Accessed: Sep. 12, 2024. [Online]. Available: https://www.sosesg.com/en/articolo/nearly-zero-energy-buildings

[103] Zach, "How to Perform One-Hot Encoding in Python," Statology. Accessed: Dec. 13, 2022. [Online]. Available: https://www.statology.org/one-hot-encoding-in-python/

[104] Z. Bobbitt, "How to Perform One-Hot Encoding in Python," Statology. Accessed: Sep. 17, 2024. [Online]. Available: https://www.statology.org/one-hot-encoding-in-python/

[105] "Machine Learning Algorithms Technical test | Test & Quiz." Accessed: Dec. 13, 2022. [Online]. Available: https://welovedevs.com/app/tests/machine-learning-algorithms

[106] D. Gong, "Top 6 Machine Learning Algorithms for Classification," Medium. Accessed: Dec. 13, 2022. [Online]. Available: https://towardsdatascience.com/top-machine-learning-algorithms-for-classification-2197870ff501

[107] M. Komorowski, D. Marshall, J. Salciccioli, and Y. Crutain, "Exploratory Data Analysis," in *Secondary Analysis of Electronic Health Records*, 2016, pp. 185–203. doi: 10.1007/978-3-319-43742-2_15.

[108] T. Rawat and V. Khemchandani, "Feature Engineering (FE) Tools and Techniques for Better Classification Performance," May 2019, doi: 10.21172/ijiet.82.024.

[109] I. H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," *SN COMPUT. SCI.*, vol. 2, no. 6, p. 420, Aug. 2021, doi: 10.1007/s42979-021-00815-1.

[110] "Ocean_NFL/2_statistics.ipynb at master · abessalov/Ocean_NFL · GitHub." Accessed: Aug. 19, 2024. [Online]. Available: https://github.com/abessalov/Ocean_NFL/blob/master/2_statistics.ipynb

[111] "Football Position Abbreviations." Accessed: Aug. 19, 2024. [Online]. Available: https://www.rookieroad.com/football-position-abbreviations-5454289/

[112] "dubai-residential-market-review-summer-2024-11505.pdf." Accessed: Sep. 27, 2024. [Online]. Available: https://content.knightfrank.com/research/2364/documents/en/dubai-residential-market-review-summer-2024-11505.pdf

[113] R. Maiorescu and A. Semenescu, "ETHICAL USE OF LARGE LEARNING MODELS IN ACADEMIA," *ACTA TECHNICA NAPOCENSIS*, Series: Applied Mathematics, Mechanics, and Engineering, Vol. 67, Issue III, September, 2024, pag.503- 508. [Online]. Available: https://atna-mam.utcluj.ro/index.php/Acta/article/view/2526

[114] R. Maiorescu and A. Semenescu, "LEVERAGING FEDERATED LEARNING FOR ENHANCED DATA MANAGEMENT PHARMACEUTICAL INDUSTRY," In: Moldovan, L., Gligor, A. (eds) The 17th International Conference Interdisciplinarity in Engineering. Inter-ENG 2023. Lecture Notes in Networks and Systems, vol 929. Springer, Cham. [Online]. Available: https://doi.org/10.1007/978-3-031-54674-7_30