
Reforma evaluării imobiliare pentru auditorii financiar utilizând IA: o explorare aprofundată a metodelor actuale și a direcțiilor viitoare

Drd. Silviu-Ionuț BĂBȚAN,
Departamentul Contabilitate și Audit, Facultatea de Științe
Economice și Administrarea Afacerilor, Universitatea
Babeș-Bolyai, Cluj-Napoca, România,
e-mail: silviu.babtan@econ.ubbcluj.ro

Rezumat

Inteligența artificială (IA, din eng. Artificial Intelligence) schimbă evaluarea imobiliară cu abordări inovatoare. Acest articol examinează mai multe metode de IA – Modele de Regresie, Arbori de Decizie, Random Forest, Rețele Neuronale Artificiale (ANN, din eng. Artificial Neural Network) și XGBoost –, explorând aplicarea acestora pentru îmbunătățirea acurateței și eficienței evaluării proprietăților, cu implicații pentru alte profesii conexe, precum auditul. Autorul începe prin a investiga limitările metodelor tradiționale de evaluare, cum ar fi constrângerile determinate de date și subiectivitatea, și prezintă modul în care tehnicile de IA analizate, care sunt implementate în domeniul evaluării proprietăților ca metode automate de evaluare, abordează aceste provocări. Modelele de Regresie cuantifică atributele, Arborele de Decizie oferă perspective clare, Random Forest îmbunătățește predicțiile, Rețelele Neuronale Artificiale creează relații elaborate, iar XGBoost furnizează tehnici avansate de stimulare pentru performanțe mai ridicate. Subliniind că IA este menită să sprijine, nu să înlocuiască evaluatorii umani, lucrarea prezintă modul în care aceste metode pot îmbunătăți procesele de evaluare, pot furniza rapoarte de evaluare mai fiabile și pot reduce erorile, explorând în același timp recomandări viitoare de cercetare și tendințele în evoluție în inteligența artificială pentru industria imobiliară și profesiile conexe.

Cuvinte cheie: inteligență artificială; evaluare imobiliară; audit; metode și tehnici automate de evaluare;

Clasificarea JEL: R30, C40, M40

Vă rugăm să citați acest articol astfel:

Băbțan, S.-I. (2025), Reforming Real Estate Valuation for Financial Auditors With AI: An In-Depth Exploration of Current Methods and Future Directions, *Audit Financiar*, vol. XXIII, no. 1(177)/2025, pp. 180-196,
DOI: 10.20869/AUDITF/2025/177/005

Link permanent pentru acest document:

<http://dx.doi.org/10.20869/AUDITF/2025/177/005>
Data primirii articolului: 11.09.2024
Data revizuirii: 30.09.2024
Data acceptării: 20.01.2025

Introducere

Inteligența artificială este un domeniu în rapidă transformare, care are influențe notabile în diferite domenii, schimbând în mod fundamental modul în care activitățile sunt realizate nu numai în afaceri, ci și în economie (Svetlana et al., 2022).

În această cercetare vom explora modul în care diferite metode IA pot fi utilizate pentru evaluarea proprietăților imobiliare. Domeniul imobiliar este dinamic și complex, cu valori ale proprietății influențate de o varietate de factori, cum ar fi dimensiunea proprietății, vechimea clădirii, locația, condițiile economice și tendințele pieței. Metodele tradiționale de evaluare depind de judecata experților și evaluările manuale, care pot fi inconsecvente, consumatoare de timp și pot fi supuse erorii umane (Choudhury, 2015). În acest context, există o necesitate din ce în ce mai accentuată pentru aplicarea metodelor automatizate în evaluarea imobiliară (AVM, din eng. *Automated Valuation Models*). Aceste metode, modele de învățare automată și algoritmi avansați, pot examina volume mari de date într-un timp scurt și cu acuratețe, oferind evaluări obiective și consistente (Zhou et al., 2017).

AVM crește eficiența, îmbunătățește fiabilitatea evaluărilor proprietății și scade costurile. Prin urmare, este un instrument prețios pentru părțile interesate și profesioniștii imobiliari în evaluarea opțiunilor de investiții și a strategiei de preț. În al doilea rând, atunci când auditează rapoartele financiare ale întreprinderilor care includ proprietăți imobiliare, auditorii acordă o atenție deosebită evaluărilor proprietăților pentru aceste active. Dacă valoarea de piață a imobilelor este prezentată în rapoartele financiare împreună cu costul istoric, auditorii trebuie să se asigure că evaluările sunt determinate cu precizie și reprezintă condițiile pieței. În acest scop, auditorii analizează rapoartele de evaluare pentru a evalua metodologiile utilizate de evaluatorii independenți, precum și așteptările și intrările de date aplicate în estimarea valorii juste de piață. Aceștia se concentrează pe factori precum similitudinea datelor de piață, adecvarea abordării evaluării (de exemplu: venituri, compararea pieței sau metode prin cost) și dacă aceste metode au fost aplicate exact în conformitate cu standardele de evaluare (Brown, 2019).

De asemenea, auditorii evaluează dacă evaluatorii au examinat toate aspectele relevante care ar putea afecta

valoarea de piață, cum ar fi condițiile economice actualizate, tendințele specifice ale pieței locale și atributele unice ale proprietății. Pentru a valida estimările din rapoartele de evaluare, auditorii ar putea compara rezultatele cu alte evaluări similare sau pot consulta profesioniștii independenți. De asemenea, se asigură că rapoartele de evaluare sunt suficient de detaliate și că dezvăluirile din rapoartele financiare subliniază clar modul în care a fost stabilită valoarea de piață, inclusiv orice variabile sau modificări potențiale. Această verificare meticuloasă este fundamentală pentru a confirma că valorile raportate în rapoartele financiare sunt aliniate cu condițiile pieței și pentru a reduce riscul raportărilor de audit inexacte, care ar putea influența deciziile acționarilor și ale altor părți interesate (Choudhury, 2015).

În ciuda acestor beneficii pentru profesiile de evaluare a proprietăților și de audit, eficiența AVM depinde de calitatea bazei de date și de expertiza tehnică a persoanelor care implementează aceste metode. Prin investigarea acestor tehnici bazate pe inteligența artificială, scopul nostru principal este să identificăm AVM care poate îmbunătăți precizia și performanța procesului de evaluare imobiliară, contribuind la rapoarte de evaluare mai cuprinzătoare și mai fiabile (Zhang, 2018).

Lucrarea își propune să ofere perspective semnificative asupra modului în care inteligența artificială poate revoluționa procesele de evaluare imobiliară, cu un impact semnificativ asupra profesiilor de contabilitate și audit care verifică estimările valorii juste. Pe măsură ce ne adâncim în complexitatea implementării inteligenței artificiale în evaluarea proprietăților, o întrebare iese în evidență: Care sunt metodele automate care pot fi utilizate în procesul de evaluare? Pentru a răspunde acestei întrebări, am analizat metode statistice complexe prezentate în literatura de specialitate care au fost utilizate pentru estimări în alte domenii de activitate, precum finanțe, comerț sau piața de capital.

În ceea ce privește metodologia de studiu, pentru a determina literatura de specialitate relevantă privind tehnicile de inteligență artificială, am realizat o abordare narativă folosind Google Scholar. După cum a recomandat Ferrari R. (2015), pentru a crește performanța abordării narrative, am împrumutat elemente din metodologia revizuirii sistematice. Prin urmare, cercetarea noastră a fost efectuată utilizând termenii: metode de inteligență artificială, predicție de regresie liniară, predicție arborilor de decizie, predicție Random Forest, predicție de rețea neuronală artificială și predicție folosind Xboost. În

lucrarea noastră, am inclus doar articole din reviste revizuite care se concentrează pe tehnicile IA menționate. Lucrările au fost, de asemenea solicitate să abordeze beneficiile și limitările și să includă indicatori de performanță. Au fost excluse lucrările fără criterii de evaluare sau care nu s-au concentrat pe IA pentru procesele de estimare. De asemenea, studiile din literatura gri au fost excluse. Aceste informații au fost folosite pentru a compara și analiza metodele din domeniile de aplicare, identificând avantajele și dezavantajele. De asemenea, am efectuat o evaluare critică a calității pentru a prioritiza lucrările revizuite cu o metodologie clară și transparentă.

Elementul de noutate adus de lucrarea noastră este că reunește toate metodele de estimare automată prezentate în literatura de specialitate. În plus, prezintă avantajele și dezavantajele fiecărei tehnici prezentate, precum și recomandări privind aplicarea metodei de predicție a valorii. Analizând și studiind diferite modele bazate pe inteligență artificială, studiul dorește să ilustreze faptul că toate aceste tehnologii pot fi soluții eficiente, fiabile și flexibile pentru a îndeplini cerințele în schimbare ale industriei imobiliare. Rezultatul analizei noastre constă în stabilirea unei metodologii clare de lucru pentru aplicarea metodelor automate de evaluare a proprietăților, indiferent de zona în care acestea se află sau perioada.

Lucrarea este organizată după cum urmează: Secțiunea 1, care oferă o privire de ansamblu asupra IA, cuprinzând definiții conceptuale, clasificări și diverse domenii de aplicare. Secțiunea 2 prezintă contextul subiectului nostru. Secțiunea 3 explorează aplicațiile IA în evaluarea imobiliară. Aceasta analizează cuprinzător fiecare model

de evaluare automatizat, afișând modul în care funcționează, avantajele și dezavantajele lor. Scopul acestei secțiuni este de a oferi o analiză exhaustivă a aplicației practice și a provocărilor legate de diferitele tehnici IA în contextul evaluării imobiliare, oferind perspective semnificative asupra limitărilor și eficacității potențialelor acestora. Ultima secțiune încheie cercetarea subliniind perspectivele și constatările cheie. De asemenea, cuprinde rezultatul, luând în considerare implicațiile IA în procesul de evaluare imobiliară și recomandând direcții viitoare de cercetare.

1. Inteligența artificială (IA): explicația conceptului, clasificări și domenii de aplicare

IA cuprinde examinarea și dezvoltarea de sisteme automate și software capabile să învețe, să raționalizeze, să dobândească cunoștințe, să manipuleze obiecte, să comunice și să le perceapă mediul (Pannu, 2015). Inteligența artificială este din ce în ce mai semnificativă în știința managementului și cercetarea operațională, unde inteligența este de obicei identificată ca o capacitate de a acumula cunoștințe și de a utiliza raționalitatea pentru a rezolva probleme complexe.

În **Tabelul nr. 1**, domeniul larg al IA este clasificat în subcategorii și domenii distincte, oferind un cadru detaliat care încapsulează aplicațiile și metodologiile variate fundamentale pentru IA. Această imagine de ansamblu nu numai că subliniază diversitatea din cadrul IA, dar sprijină și o înțelegere mai clară a naturii sale complexe.

Tabelul nr. 1. Domeniile de aplicabilitate pentru Inteligența Artificială	
Categorie	Subcategorii
A. Aplicabilitate în științe cognitive	<ul style="list-style-type: none"> • <i>Sisteme de învățare,</i> • <i>Agenți inteligenți,</i> • <i>Sisteme Expert,</i> • <i>Algoritmi genetici,</i> • <i>Rețele neutre,</i>
B. Aplicabilitate în interfețe naturale	<ul style="list-style-type: none"> • <i>Limbi naturale,</i> • <i>Realitatea virtuală,</i> • <i>Recunoașterea vorbirii,</i>
C. Înțelegerea vorbirii și procesarea semantică	<ul style="list-style-type: none"> • <i>Traducerea limbii,</i> • <i>Înțelegerea vorbirii,</i> • <i>Recuperarea informațiilor,</i> • <i>Prelucrarea informațiilor semantice,</i>

Categorie	Subcategorii
D. Sisteme de învățare și adaptare	<ul style="list-style-type: none"> Formarea conceptelor, Cibernetică,
E. Rezolvarea de probleme	<ul style="list-style-type: none"> Inferență, Scrierea automată a programelor, Căutare euristică, Rezolvarea interactivă a problemelor,
F. Percepție (Vizuală)	<ul style="list-style-type: none"> Analiza scenei, Recunoașterea modelelor,
G. Modelare	<ul style="list-style-type: none"> Problema de reprezentare pentru sistemele de rezolvare a problemelor, Modelarea sistemelor naturale,
H. Robotică Aplicată	<ul style="list-style-type: none"> Dexteritate, Percepții vizuale, Navigare, Locomoție,
I. Robotică	<ul style="list-style-type: none"> Automatizare industrială, Explorare, Transport/Navigație, Militar, Securitate, Gospodărie, Altele,
J. Jocuri	<ul style="list-style-type: none"> Jocuri

Sursă: Prelucrare proprie a autorului, bazată pe informațiile furnizate de Khanzode et al. (2020) și Pannu (2015)

După cum este ilustrat în **Tabelul nr. 1**, IA cuprinde o varietate extinsă de domenii, variind de la realitatea virtuală și implementarea roboticii care optimizează procesele tehnice și industriale, până la examinarea datelor vizuale și generarea de tehnici de prognoză. Această varietate prezintă acoperirea largă și aplicațiile diverse ale IA. Tabelul arată că în diferite ramuri ale IA aplicațiile științei cognitive pot fi implementate cu succes în evaluarea imobiliară. Această categorie încorporează tehnici fundamentale de IA, care cuprind modele și sisteme de învățare utilizate pentru o diversitate de sarcini de estimare și predicție.

În contabilitate și audit introducerea IA a generat îngrijorări în rândul experților cu privire la potențiala deplasare a forței de muncă (Mohammad et al., 2020). Cu toate acestea, o perspectivă mai rafinată indică faptul că IA nu îi va înlocui pe evaluatori și contabili, ci le va îmbunătăți capacitățile. IA poate gestiona sarcini de rutină și consumatoare de timp, permițând contabililor și auditorilor să se concentreze asupra activităților complexe și cu valoare adăugată mai mare. Această schimbare poate duce la îmbunătățirea acurateței și a performanței, reducând timpul de lucru petrecut de profesioniștii

contabili și, în cele din urmă, sporind eficiența generală a industriei contabilității.

Metodele de Inteligență Artificială propuse în lucrare au fost implementate cu succes în alte domenii de activitate. Ca urmare, subliniem posibilitatea integrării acestor metode în procesul de evaluare a proprietății. **Tabelul nr. 2** evidențiază principalele domenii în care aceste metode au fost aplicate cu succes.

După cum se arată în **Tabelul nr. 2**, metodele IA sunt utilizate în estimare în diverse domenii, de la domeniul medical până la cel economic, financiar sau energetic. În literatura de specialitate observăm că toate metodele propuse de noi pentru evaluarea proprietăților imobiliare au fost deja utilizate în estimările de preț în alte domenii, precum prețul acțiunilor (Vaiz et al., 2016, Voung et al., 2022), prețul aurului (Mombeini et al., 2015, Manoj et al., 2019), prețul energiei electrice (Saini et al. 2016, González et al. 2016) sau chiar prețul Bitcoin (Ramani K. et al. 2023). În consecință, considerăm că metodele acestea pot fi implementate practic în evaluarea proprietăților imobiliare.

Există, de asemenea, o sinergie între evaluarea imobiliară și audit. Pentru a înțelege scopul evaluării, este esențial să ne referim la standardele și conceptele de evaluare, care oferă bazele conceptuale ale acestei metode. Obiectivul principal al evaluării proprietății este de a stabili valoarea acesteia într-un context specific, fie că este vorba de finanțare,

tranzacții de vânzare, raportare financiară sau impozitare (Smith, 2020). În special în contextul raportării financiare, obiectivele evaluării sunt să reflecte o valoare justă de piață, care este utilă și relevantă pentru utilizatorii rapoartelor financiare, cum ar fi creditorii, investitorii și alte părți interesate (Johnson și Williams, 2021).

Tabelul nr. 2. Implementarea practică a metodelor IA		
Autor	Metoda IA	Variabilă estimată
Goundar S. et al. (2021)	Regresie liniară	Evaluarea proprietății
Boztosun D. et al. (2016)		Creșterea economică
Zhou T. et al. (2013)		Puterea de captare a carbonului
Roy S. et al. (2015)		Cursurile bursiere
Saini D. et al. (2016)		Prețul energiei electrice
Ge Y. et al. (2020)		Prețul porumbului
Khan Z. et al. (2022)		Prețul mașinii uzate
Manoj J. et al. (2019)		Prețul aurului
Oba K. M. (2019)		Prețul cimentului
Lasota T. et al. (2013)	Arbori de decizie	Evaluarea proprietății
Padmanaban K. A. et al. (2016)		Boală cronică de rinichi
Ghosh A. et al. (2021)		Riscul de eroziune a solului
Aji N. A. et al. (2019)		Scor de credit
Bhatnagar R. et al. (2020)		Randamentul culturii
Sisodia D. et al. (2018)		Diabet
Putra P.H. et al. (2023)		Prețul mașinii
Vaiz J.S. et al. (2016)		Prețul stocului
Nwulu N.I. et al. (2017)		Prețul petrolului
Goundar S. et al. (2021)	Random Forest	Evaluarea proprietății
Langsetmo L. et al. (2023)		Risc de fractură de șold
Langsetmo L. et al. (2023)		Riscul de mortalitate
Khaidem L. et al. (2016)		Prețul Bursei
González C. et al. (2016)		Prețul energiei electrice
Ghosh A. et al. (2021)		Riscul de eroziune a solului
Aji N. A. et al. (2019)		Scorul de credit
Bhatnagar R. et al. (2020)		Randamentul culturii
Putra P.H. et al. (2023)		Prețul mașinii
Shanbehzadeh M. et al. (2022)	Neural Network	Mortalitatea prin Covid-19
Yan K. et al. (2019)		Consum de energie
Khan Z. H. et al. (2011)		Prețul pieței de acțiuni
Jha G. K. et al. (2013)		Prețul Agricol
Ugurlu U. et al. (2018)		Prețul energiei electrice
Nikolaev D. et al. (2021)		Prețul acțiunilor
Zhou Y. et al. (2019)	Extreme Gradient Boosting	Prețul țiteiului
Ma B. et al. (2020)		Clasificarea diagnostică a cancerelor
Young P.H. et al. (2022)		Prețul stocului
Nandigala Venkat Anurag Y. et al. (2019P)		Indicele de calitate a aerului
Ramani K. et al. (2023)		Prețul Bitcoin

Sursă: Compoziție proprie a autorului

Rolurile auditorului și ale evaluatorului se intersectează într-un mod crucial. Evaluatorul este responsabil pentru utilizarea metodologiilor pentru a determina valoarea justă de piață a unei proprietăți, luând în considerare toți factorii relevanți de piață, inclusiv condițiile economice reale și atributele specifice ale proprietății (Brown, 2019). Pe de altă parte, auditorul are sarcina de a valida și verifica această evaluare, asigurându-se că metoda utilizată este corectă și că rezultatele sunt reflectate cu acuratețe în rapoartele financiare. Prin urmare, colaborarea dintre auditor și evaluator este crucială pentru a se asigura că valorile raportate în rapoartele financiare sunt precise, în concordanță cu realitățile pieței și conforme cu standardele de raportare financiară și contabilitate (Davis și Taylor, 2022).

2. Inteligența Artificială în evaluarea automată a proprietăților imobiliare

În ultimele decenii, IA a început să transforme diverse sectoare, inclusiv evaluarea proprietăților. Aplicarea IA în acest domeniu oferă avantaje semnificative, cum ar fi eficiența și acuratețea sporite în determinarea valorii juste a proprietăților imobiliare. Acest lucru este important pentru auditorii financiari, care doresc să valideze evaluările corecte ale valorii împărtășite în rapoartele financiare ale companiilor (Smith, 2020).

IA permite evaluarea automată a proprietăților prin aplicarea unor algoritmi complecși de învățare automată care examinează datele curente și istoricul tranzacțiilor imobiliare. Acești algoritmi ar putea procesa rapid cantități masive de date, oferind estimări comparative precise și rapide. De exemplu, prin examinarea datelor privind locația, prețurile de vânzare, caracteristicile, dimensiunea și starea proprietății, IA poate genera estimări ale valorii de piață utilizate atât de auditori, cât și de evaluatori (Johnson și Williams, 2021).

În plus, beneficiul IA în evaluarea imobiliară este capacitatea sa de a detecta modele și tendințe pe care evaluatorii le-ar putea subestima sau trece cu vederea. De

exemplu, IA ar putea recunoaște schimbări subtile ale tendințelor pieței imobiliare care ar putea indica potențiale modificări ale prețurilor. Acest lucru ajută la reducerea riscurilor de subevaluare sau supraevaluare a proprietăților imobiliare, care ar putea afecta semnificativ situațiile financiare ale unei companii (Brown, 2019), de unde activitatea auditorilor și contabililor.

Chiar și așa, utilizarea inteligenței artificiale în evaluarea imobiliară aduce propriul obstacol. În timp ce algoritmi de învățare automată ar putea oferi estimări eficiente și rapide, claritatea lor depinde în mare măsură de cantitatea și calitatea datelor disponibile și valide. În plus, modelele IA ar putea fi afectate de erori sistemice și părtiniri, ar putea duce la evaluări inexacte. Prin urmare, este esențial pentru evaluatori și auditori să identifice riscurile și limitările legate de aceste instrumente și să le completeze cu expertiză și raționament profesional pe piața imobiliară (Davis și Taylor, 2022).

Evaluarea imobiliară este un proces critic, cu aplicații extinse în diverse domenii, care afectează atât instituțiile, cât și persoanele fizice. Îndeplinește o funcție semnificativă în tranzacțiile imobiliare prin stabilirea prețurilor obiective de piață și determinarea ratelor de închiriere adecvate pentru contractele de închiriere (Büyükkaraciğan, 2021).

În acest studiu, ne concentrăm pe avansarea metodelor de evaluare imobiliară prin explorarea AVM. Examinăm modul în care tehnicile inovatoare pot îmbunătăți eficiența, acuratețea și eficacitatea generală a proceselor de evaluare. Cercetarea noastră evidențiază o analiză comparativă a cinci tehnici de sisteme de învățare, inclusiv Arborele de decizie, Rețelele neuronale artificiale, Regresia liniară, Random Forest și XGBoost. Acest proces cuprinde evaluarea performanței fiecărei tehnici folosind metrici, de exemplu, eroarea medie pătratică care examinează variațiile dintre valorile reale și valorile prezise (Hodson, 2022). Analizând aceste metode, ne propunem să recomandăm noi tehnici care ar putea revoluționa practicile de evaluare și să ofere soluții mai scalabile și mai fiabile pentru piața imobiliară și pentru profesiile conexe.

Tabelul nr. 3. Tehnici avansate de evaluare automată a proprietăților

Categorie	Subcategorie	Tehnică
Aplicații ale științei cognitive	Sisteme de învățare	Regresie liniară
		Arbori de decizie
		Random Forest
		Artificial Neural Networks (ANN)
		XGBoost

Sursă: Compoziție proprie a autorului

Aceste metode sunt componente ale sistemelor de învățare din cadrul aplicațiilor științelor cognitive. Modelele și metodele aplicațiilor științelor cognitive sunt concepute pentru a învăța din baza de date și pentru a face predicții precise (Tabelul nr. 3).

Pentru a putea alege care dintre metodele propuse în studiu este cea mai fezabilă și de încredere pentru o anumită regiune, studiul de față propune o analiză comparativă între rezultatele obținute prin fiecare metodă. Acest pas cuprinde evaluarea performanței fiecărei tehnici folosind metrici, de exemplu, eroarea medie pătratică (RMSE), care examinează variațiile dintre valorile reale și valorile prezise (Hodson T. O. 2022).

3. Tehnici în evaluarea imobiliară și implicațiile acestora

3.1. Regresia liniară

Regresia liniară este o metodă primară de estimare a rezultatelor cantitative și, în ciuda longevității sale istorice, rămâne una dintre cele mai eficiente și utilizate tehnici pe scară largă în statistică. Deși ar putea părea mai puțin avansată în contrast cu alte abordări statistice pe care le vom discuta în continuare în această lucrare, regresia liniară este încă un instrument crucial în analiza datelor. În plus, regresia liniară funcționează ca un element vital pentru metode mai elaborate: metodele contemporane de învățare statistică pot fi considerate generalizări sau extensii ale acestei tehnici (James et al., 2023). Această metodă a fost aplicată cu succes în alte cercetări din literatura de specialitate (Goundar S. et al. 2021, Sipos C. et al. 2008), reușind astfel să-și demonstreze aplicabilitatea în domeniul imobiliar.

Având în vedere natura complexă a procesului de evaluare imobiliară și numeroasele atribute care influențează prețurile proprietăților, bazat exclusiv pe modele de regresie liniară pentru predicții este insuficientă. Pentru a automatiza procesul de evaluare și a obține rezultate precise este obligatoriu să testăm mai multe modele de regresie. Aceste tehnici reprezintă o gamă mai largă de variabile de influență, oferind o abordare mai fiabilă și mai aprofundată a evaluării valorilor proprietăților. Popularitatea pe scară largă a regresiei multiple derivă din aplicabilitatea sa universală la o varietate de probleme și date (Wang, 2003).

Regresia liniară este preferată pentru robustețea sa împotriva încălcării premiselor esențiale, interpretarea sa

clară și disponibilitatea sa largă prin diferite programe statistice. Aceste avantaje fac din regresia liniară un instrument de bază pentru analiști și cercetători care urmăresc să măsoare relațiile dintre variabile și să creeze predicții de încredere (Korkmaz, 2021).

În exemplul de mai jos vom investiga modul în care regresia multiplă poate fi utilizată pentru a estima valoarea imobiliară luând în considerare mai multe atribute independente, cum ar fi vârsta clădirii, dimensiunea casei, numărul de dormitoare, numărul de camere, accesibilitatea zonei, a orașului, a străzii și nivelul de finisare (Putra et al., 2023). Formula pentru modelul nostru de regresie multiplă poate fi exprimată astfel:

$$Y = \beta_0 + \beta_1(\text{Numărul de camere}) + \beta_2(\text{Dimensiune}) + \beta_3(\text{Numărul de dormitoare}) + \beta_4(\text{Oraș}) + \beta_5(\text{Strada}) + \beta_6(\text{Accesibilitate}) + \beta_7(\text{Vârsta clădirii}) + \beta_8(\text{Nivelul de Finisare}) + \beta_9(\text{Dimensiunea lotului}) + \beta_{10}(\text{Evaluarea școlii}) + \beta_{11}(\text{Dimensiunea garajului}) + \beta_{12}(\text{Dimensiunea grădini}) + \beta_{13}(\text{Funcții de securitate}) + \beta_{14}(\text{Eficiență energetică}) + \dots + \beta_n + \epsilon,$$

unde:

Y – variabila dependentă, reprezentând prețul casei;

β_0 – termenul constant; valoarea așteptată a prețului atunci când toate variabilele independente sunt egale cu zero;

$\beta_{1:n}$ – vectorul coloană al coeficienților 1:n;

ϵ – termenul rezidual sau de eroare, variația prețului neexplicată de model.

Este de remarcat faptul că alegerea atributelor potrivite pentru modelul de regresie este o procedură fundamentală. Aceasta implică selectarea numai a atributelor care au un efect semnificativ asupra prețului și asigurarea unui set larg de variabile care să reflecte cu exactitate complexitatea pieței imobiliare. În conformitate cu Heinze et al. (2018), mai multe tehnici pot fi aplicate în procesul de selecție a atributului. Aceste abordări includ selectarea atributelor bazate pe criterii de informare sau semnificație, aplicarea probabilității penalizate, implementarea cunoștințelor de bază, utilizarea criteriului de modificare a estimării sau utilizarea unei combinații a acestor tehnici. Un set de atribute alese cu grijă ajută la creșterea fiabilității și acurateței modelului în prezicerea valorilor imobiliare, validând faptul că rezultatele reflectă diferitele condiții de pe piață.

Cu toate acestea, regresia liniară are câteva slăbiciuni semnificative. Presupune o relație liniară între variabilele

independente și dependente, care poate să nu fie întotdeauna exactă în practică, și este foarte sensibilă la valorile aberante care pot deforma rezultatul (Rousseeuw et al., 2005). În plus, există problema multicolinearității, care poate genera estimări de coeficienți nesigure. Abordarea presupune, de asemenea, independența erorilor și homoscedasticitatea, presupuneri care sunt adesea încălcate în practică. În plus, regresia liniară poate sub-adapta sau supra-adapta datele și se luptă cu seturi de date complexe. De asemenea, presupune reziduuri distribuite normal și abateri care pot afecta intervalele de încredere și testele de ipoteză (James et al., 2013).

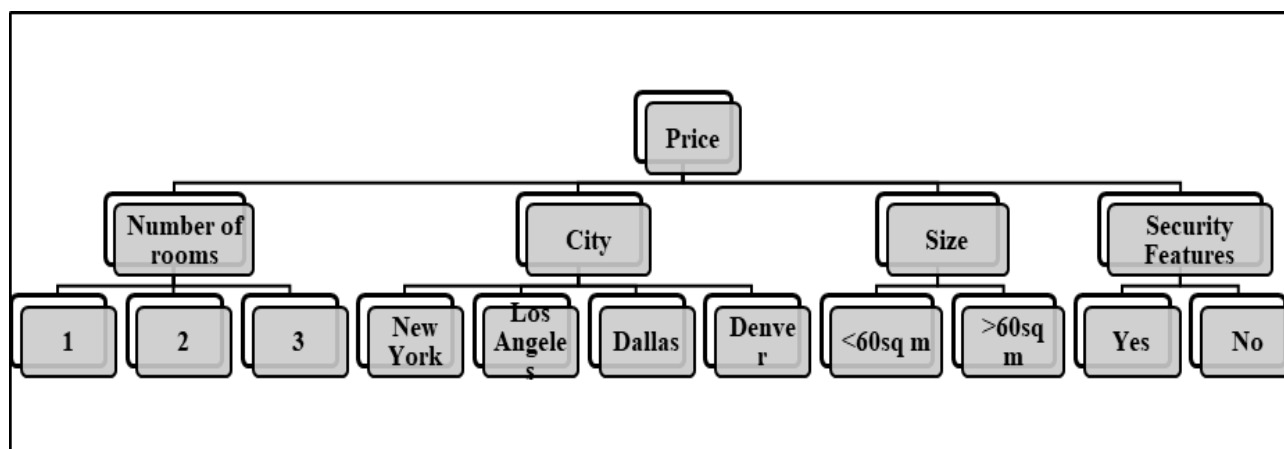
În următoarea parte a lucrării vom explora metode de estimare mai avansate, menite să depășească slăbiciunea modelului de regresie liniară.

3.2. Arborele de decizie

Un arbore de decizie este un model de învățare ghidată care structurează un domeniu de date într-un model ierarhic, transpunându-l într-un set de rezultate. Împarte iterativ domeniul de date în subdomenii, asigurându-se că fiecare împărțire obține un câștig de informații mai mare decât nodul anterior, ceea ce duce la o creștere a puterii de predicție (Suthaharan, 2016).

Pentru o mai bună înțelegere a procesului, vom ilustra în *Figura nr. 1* o structură simplificată. Un arbore de decizie este un tip de date organizate în mai multe noduri, fiecare legat de ramuri. Nodurile care au margini de ieșire sunt noduri interne, iar celelalte se numesc frunze (Pekel, 2020). În timp ce acest model de bază ajută la înțelegerea structurii fundamentale a unui arbore de decizie, se recomandă, în practică, utilizarea unui număr mai mare de variabile pentru a crește acuratețea predicției. Scopul *Figurii nr. 1* este de a înțelege modul în care diverse variabile pot afecta prețul, care este variabila țintă în acest context.

Figura nr. 1. Arborele de decizie în procesul de evaluare



Sursă: Compoziție proprie a autorului

La rădăcina arborelui se află prețul, variabila țintă, pe care dorim să o prognozăm pe baza mai multor variabile de influență. Primul nivel de filiale împarte procesul de decizie în categorii: orașul proprietății, dimensiunea proprietății, numărul de camere și prezența elementelor de securitate. Prima variabilă este numărul de camere cu trei posibilități: 1, 2 sau 3 camere. Al doilea factor este orașul în care se află proprietatea, care se ramifică în: New York, Los Angeles, Dallas și Denver. A treia variabilă este dimensiunea proprietății, care se împarte în: proprietăți

mai mici de 60 mp și proprietăți mai mari de 60 mp. După aceea, variabila „caracteristici de securitate” diferențiază proprietățile cu și fără caracteristici de securitate Choudhury (Gupta et al., 2017).

Acest arbore de decizie exemplificat ilustrează structura ierarhică și conceptul de arbori de decizie ca instrument educațional. Prin includerea mai multor variabile, se poate construi un model mai precis și mai robust pentru estimarea variabilelor țintă, cum ar fi valorile imobiliare.

Arborele de decizie reprezintă o opțiune eficientă și accesibilă pentru analiza datelor datorită simplității lor. Sunt ușor de vizualizat și înțeles și ușor de interpretat. Spre deosebire de alte metode care necesită adesea pregătirea minuțioasă a datelor, cum ar fi eliminarea valorilor necompletate, normalizarea sau crearea de variabile fictive, arborii de decizie necesită un nivel minim de preprocesare (Gupta et al., 2017). În plus, metoda generează rezultate precise prin utilizarea unor măsuri precum Entropia, indicele Gini și prin câștig de informații (eng. *Information Gain*) pentru a identifica împărțirea optimă la fiecare nod (Jadhav et al., 2016). Aceste măsuri contribuie la examinarea și selectarea celor mai bune variabile pentru împărțirea datelor, asigurându-se că fiecare divizare diminuează impuritățile și maximizează separarea claselor din setul de date (Dash, 2022).

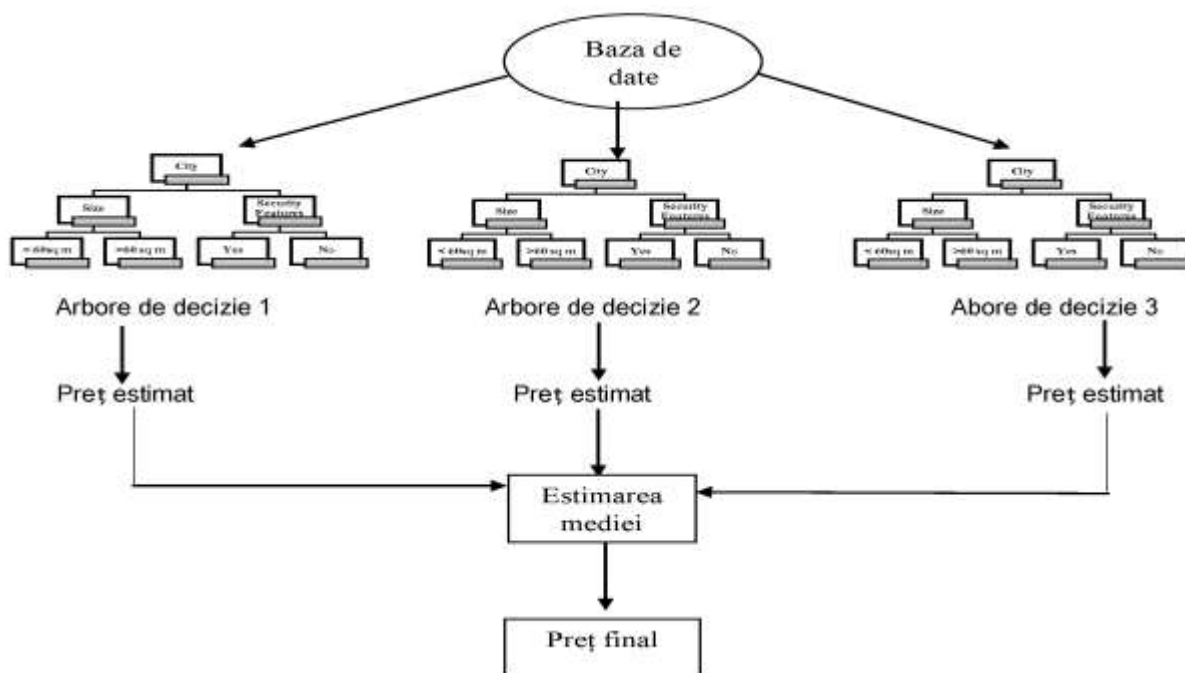
În ciuda punctelor forte, arborii de decizie au mai multe dezavantaje. Sunt volatili, variațiile minime ale datelor pot modifica în mod deosebit structura arborelui și sunt, de asemenea, susceptibili la supra-adaptare, detectând mai degrabă zgomotul decât modelele subiacente, ceea ce le scade generalizarea și acuratețea (Pehel, 2020). Aceste limitări pot influența fiabilitatea evaluărilor imobiliare.

3.3. Random Forest

Dezvoltată de Breiman (2001), metoda Random Forest s-a demonstrat a fi un instrument extrem de eficient atât pentru sarcinile de regresie, cât și pentru cele de clasificare. Acest algoritm funcționează prin generarea mai multor arbori de decizie randomizați și apoi prin fuzionarea predicțiilor acestora prin mediere (Biau et al., 2016). Fiecare nod al arborelui de decizie alege aleatoriu un subset de factori din întregul set de date și fiecare arbore utilizează un eșantion bootstrap unic de date, comparabil cu metoda bagging (Oshiro et al., 2012). Excelează mai ales în situațiile în care numărul de variabile depășește semnificativ numărul de observații. În plus, Random Forest este personalizabilă pentru o gamă largă de probleme extinse, ușor de adaptat pentru sarcini specifice de învățare și oferă perspective esențiale asupra semnificației variabilei.

Pentru a îmbunătăți înțelegerea algoritmului Random Forest vom aplica același exemplu utilizat anterior în analiza arborelui de decizie. Această abordare ne va permite să analizăm și să comparăm metodologiile care stau la baza avantajelor și caracteristicilor specifice ale Random Forest.

Figura nr. 2. Random Forest în procesul de evaluare



Sursă: Compoziție proprie a autorului

În exemplul din *Figura nr. 2*, fiecare arbore de decizie din Random Forest va evalua în mod autonom caracteristicile proprietății, cum ar fi dimensiunea, orașul și caracteristicile de securitate, pentru a estima variabila țintă, adică prețul. De exemplu, un arbore se poate concentra pe dimensiune și oraș, în timp ce altul ar putea prioritiza caracteristicile de securitate și dimensiunea. Această variație între copaci permite algoritmului Random Forest să capteze o gamă largă de relații și modele în cadrul datelor.

După ce toți copacii și-au făcut previziunile individuale ale valorii proprietății, aceste estimări sunt consolidate prin mediere. Prin combinarea estimărilor mai multor arbori, Random Forest diminuează riscul de supra-adaptare, care este o limitare semnificativă a arborilor cu decizie unică. Etapa de mediere reduce, de asemenea, impactul distorsiunilor sau anomaliilor prezentate în arbori individuali, contribuind la o predicție mai robustă și mai precisă.

Prin urmare, Random Forest este o versiune îmbunătățită a unui arbore de decizie, aplicând mai mulți clasificatori în loc de unul pentru a îmbunătăți fiabilitatea și acuratețea predicțiilor pentru instanțe viitoare (Shaik et al., 2019). În plus, oferă mai multe avantaje, inclusiv măsurarea semnificației fiecărui atribut din setul de date de antrenament, predicții precise pentru o gamă largă de aplicații și evaluarea distanței perechi dintre eșantioane din datele de antrenament (Prajwala, 2015).

Cu toate acestea, procesul de instruire a modelelor Random Forest poate consuma foarte multe resurse, mai ales atunci când avem de-a face cu seturi de date extinse și mulți arbori. Acest lucru solicită putere de procesare și memorie semnificative, prezentând o provocare pentru aplicațiile care necesită predicții în timp real (Hengl, 2018).

Reproducerea și validarea rezultatelor modelului Random Forest poate prezenta provocări datorită complexității lor. Obținerea unor rezultate fiabile necesită menținerea aceluiași configurații de model și semințe aleatorii, care pot fi mai puțin transparente și împovărătoare decât alte tehnici (Biau, 2012).


3.4. Artificial Neural Network

Rețelele neuronale artificiale sunt un subiect cheie în IA, inspirat de funcția și structura creierului uman. Ele modelează procesarea informațiilor și memoria, generând modele elementare care reproduc rețelele neuronale ale creierului. Aceste modele conectează diverse rețele în moduri diferite, pentru a procesa informații în mod similar creierului uman (WU, 2018).

Un ANN este format din neuroni interconectați și fiecare neuron poate primi, procesa și transmite semnale. Această rețea încorporează sinapse ponderate, care agregă datele de intrare în funcție de aceste ponderi și un mecanism de activare care restricționează amplitudinea de ieșire a neuronului, permițând rețelei să execute calcule avansate prin imitarea procesului neuronal al creierului (Zhang, 2018).

Chiar dacă înțelegerea unei ANN poate fi complicată, o vom prezenta simplu, printr-un exemplu practic. În mod explicit, vom prezenta modul în care ANN poate prezice valoarea proprietății pe baza a trei variabile independente: suprafața în mp, orașul și vechimea clădirii. În predicțiile practice, includerea unui număr mai mare de atribute într-un set de date este vitală pentru a asigura acuratețea predicției.

Figura nr. 3. ANN în evaluarea automată



Sursă: Compoziție proprie a autorului

În *Figura nr. 3*, stratul de intrare al rețelei neuronale artificiale include trei noduri, reprezentând variabilele cheie care influențează valorile imobiliare: orașul, dimensiunea în m.p. și vechimea clădirii în ani. Fiecare nod de intrare este echivalent cu o variabilă specifică a proprietății evaluate. Primul nod captează datele despre locație. Suprafața în nodul m.p. codifică suprafața proprietății, iar vechimea nodului proprietății ține cont de vechimea clădirii, care poate influența valoarea și starea acesteia de piață. ANN cuprinde două straturi ascunse cu mai mulți neuroni marcați cu H. Aceste straturi ascunse analizează intrările prin conexiuni ponderate și mecanism de activare, captând relații neliniare avansate între variabile. Stratul de ieșire, care este prețul, exemplul nostru, a fuzionat informațiile procesate pentru a genera valoarea estimată a proprietății. Această structură ANN modelează și prezice valoarea proprietății pe baza atributelor specificate, utilizând adâncimea straturilor ascunse pentru a îmbunătăți acuratețea predicției.

Un principal avantaj al algoritmului ANN este că reține informațiile în întreaga rețea, în loc să fie într-o singură bază de date. Prin urmare, pierderea informațiilor într-o parte a rețelei nu împiedică funcționarea generală a acesteia (Khalilov, 2021). Rețeaua neuronală artificială are o toleranță superioară la erori și este renumită pentru scalabilitatea și viteza ridicată, în special atunci când se utilizează procesarea paralelă (Zou et al., 2009). Aceasta poate gestiona intrări și ieșiri binare sau date simbolice atunci când sunt codificate corect, asigurând o aplicabilitate largă în diferite domenii (Wang S.C. et al. 2003). Mai mult, ei pot învăța din mediul înconjurător, astfel încât pot fi utilizați pentru date sau sarcini complexe în care alte tipuri de soluții sunt impracticabile (Krenker, 2011).

Rețelele neuronale artificiale au propriile lor dezavantaje, de exemplu, înclinația de a cădea în minime locale și dificultatea de a-și adapta arhitectura (Ding S. et al. 2013). În plus, poate fi o provocare să fie ajustate și optimizate pentru sarcini specifice (Abiodun et al., 2018). Pentru a îmbunătăți generalizarea rețelei este necesar să se utilizeze o rețea suficient de mare pentru a oferi o potrivire adecvată, deoarece rețelele mai mari permit crearea de funcții mai elaborate (Dongare et al., 2012).

3.5. Extreme Gradient Boosting

Extreme Gradient Boosting este o tehnică avansată, bazată pe alte tehnici de boosting, cum ar fi arbori de clasificare amplificați și AdaBoost (Carmona și colab.,

2019). Extreme Gradient Boosting (XGBoost) poate fi utilizată atât pentru probleme de clasificare, cât și pentru probleme de regresie și este preferat de către cercetătorii de date pentru abilitățile sale de calcul în afara nucleului și performanța rapidă, făcând-o potrivită pentru gestionarea capabilă de seturi de date mari (Osman et al., 2021). Utilizează un mecanism conștient de dispersie care gestionează variabilele cu intrări lipsă sau valori zero, omițând automat aceste intrări din calculul câștigului pentru candidații divizați, crescând astfel performanța modelului (Bentéjac et al., 2021).

Aplicând același exemplu ca în tehnicile anterioare, vom ilustra funcționarea și structura XGBoost (*Figura nr. 4*). Metoda începe prin introducerea setului de date, care include variabilele: oraș, dimensiune și caracteristici de securitate.


Prima etapă constă în a antrena arborele de decizie inițial utilizând aceste atribute pentru a estima inițial valoarea proprietății. Se calculează apoi variația dintre valoarea estimată și valoarea reală, identificată ca reziduuri, care stau la baza erorilor produse de primul arbore.

Ulterior, al doilea arbore de decizie este antrenat pe aceste reziduuri cu scopul de a corecta erorile inițiale, crescând astfel acuratețea modelului. Acest proces de antrenare a arborilor succesivi și de calculare a reziduurilor continuă, iar fiecare arbore nou este concentrat pe corectarea erorilor arborilor anteriori.

În exemplu am inclus un al treilea arbore de decizie, pentru a îmbunătăți predicția valorii prin abordarea reziduurilor din estimările celui de-al doilea arbore. Predicția finală a valorii proprietății este derivată prin îmbinarea rezultatelor tuturor arborilor de decizie. Acest proces repetitiv, numit boosting, facilitează XGBoost să dezvolte un model precis și performant datorită îmbunătățirii constante a estimărilor prin diferite etape de corectare a erorilor, conducând la o predicție precisă a valorii.

Principalele caracteristici ale XGBoost cuprind capacitatea sa de a gestiona inputuri rare atât pentru boosteri liniare, cât și pentru boosteri de arbore, suport pentru obiective personalizate și funcții de evaluare și performanță ridicată constantă în diverse seturi de date (Chen T. et al. 2015). Succesul său se datorează eficienței și scalabilității, deoarece rulează cu o viteză de zece ori mai mare decât a altor algoritmi de învățare automată (Shilong, 2021). Mai mult decât atât, XGBoost include o funcție de regularizare în scopul său de a îmbunătăți generalizarea modelului și de a preveni supraadaptarea (Zhou et al., 2021).

Figura nr. 4. Extreme Gradient Boosting în procesul de evaluare automată



Sursă: Compoziție proprie a autorului

O limitare a algoritmului XGBoost este dispoziția acestuia la supraadaptare care, dacă nu este gestionată corespunzător, poate avea ca rezultat doar performanță medie pe seturile de date de validare sau de testare, chiar dacă are o performanță excepțională pe setul de date de antrenament (Drahokoupil, 2022).

Concluzii

În concluzie, explorarea tehnicilor de inteligență artificială pentru evaluarea imobiliară expune potențialul notabil de schimbare a evaluării tradiționale. Piața imobiliară, definită prin complexitatea și vulnerabilitatea sa la diferiți factori, are potențialul de a beneficia semnificativ de implementarea tehnicilor bazate pe inteligență artificială. Metodele automate ale tehnicilor de evaluare pot evalua cu acuratețe și rapid seturi de date complete, oferind o evaluare consecventă și fiabilă a proprietăților.

Mecanismele de inteligență artificială pot spori în mod deosebit fiabilitatea evaluărilor imobiliare, pot reduce costurile și pot îmbunătăți eficiența. Cu toate acestea, eficiența tehnicilor IA depinde de cunoștințele tehnice ale profesioniștilor care execută aceste modele și de calitatea datelor utilizate. În consecință, este esențial pentru evaluatorii imobiliari să asigure calitatea înaltă a datelor și să dobândească abilitățile necesare pentru implementarea eficientă a metodelor IA.

În lucrare am examinat avantajele și limitările a cinci metode de predicție bazate pe inteligență artificială care pot fi aplicate în evaluarea imobiliară. Fiecare tehnică are propriile puncte slabe și puncte forte, iar performanța lor poate diferi în funcție de setul de date specific. Având în vedere complexitatea și variația datelor imobiliare, nicio tehnică unică nu asigură cele mai eficiente rezultate în orice circumstanță. În consecință, recomandăm o abordare amănunțită în care toate metodele IA prezentate

sunt testate în raport cu setul de date disponibil. Astfel, profesioniștii pot identifica practic care metodă generează cele mai precise predicții. Acest proces cuprinde evaluarea performanței fiecărei tehnici folosind metrici, de exemplu, eroarea medie pătratică care examinează variațiile dintre valorile reale și valorile prezise. Evaluând și comparând riguros toate tehnicile, experții imobiliari pot lua decizii bazate pe date care îmbunătățesc precizia și fiabilitatea evaluărilor proprietăților.

În opinia noastră, este esențial ca auditorii sau experții pe care se bazează pentru a verifica valoarea justă și raportul de evaluare care stă la baza estimării valorii juste să fie bine informați cu privire la evaluările automatizate bazate pe IA. De asemenea, auditorii trebuie să înțeleagă temeinic modul în care funcționează aceste modele bazate pe inteligență artificială, inclusiv metodologiile lor, intrările de date și limitările potențiale pentru a le implementa cu succes. Aceste cunoștințe sunt esențiale pentru a ne asigura că valoarea justă raportată în situațiile financiare este exactă, fiabilă și transparentă, menținând astfel credibilitatea informațiilor financiare prezentate investitorilor și altor părți interesate.

Din perspectiva noastră, contribuția adusă de utilizarea metodelor automate de evaluare este semnificativă. În prima etapă, în cadrul procesului de implementare sunt necesare timp și resurse financiare importante pentru a colecta date și a compara toate cele cinci metodele

propușe. Dar odată ce a fost selectată metoda cea mai potrivită, orice evaluare a proprietății se poate face în câteva secunde fără a genera costuri suplimentare. Singurul efort cerut de evaluator este introducerea în sistem a caracteristicilor proprietății, iar în câteva secunde programul va calcula automat prețul. Prin urmare, odată cu implementarea metodei de evaluare se vor înregistra în practică economii substanțiale atât de timp, cât și de resurse umane, precum și o creștere a acurateței.

Privind în viitor, cercetarea și dezvoltarea susținută în IA va fi vitală pentru îmbunătățirea în continuare a performanței și preciziei evaluărilor imobiliare. Cercetările viitoare ar trebui să investigheze provocările identificate în lucrare, cum ar fi calitatea datelor și implementarea modelului, și să examineze noi algoritmi IA care ar putea oferi avantaje mai mari. Salutând aceste progrese, piața imobiliară se poate îndrepta către evaluări mai eficiente, fiabile și scalabile, susținând deciziile de preț și investițiile.

Prin urmare, inteligența artificială este o oportunitate revoluționară pentru piața imobiliară, oferind o mai bună consistență, acuratețe și eficiență. Cunoștințele dobândite din această lucrare oferă o bază solidă pentru explorarea și implementarea continuă a IA în evaluarea imobiliară, facilitând progresul către un viitor în care metodele automate de evaluare devin fundamentale pentru procedurile standard.

Bibliografie

1. Abiodun O. I., Jantan A., Omolara A. E., Dada K. V., Mohamed N. A., & Arshad H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11)
2. Aji N. A., & Dhini A. (2019, July). Credit scoring through data mining approach: A case study of mortgage loan in Indonesia. *2019, 16th International Conference on Service Systems and Service Management (ICSSSM)*, pp. 1-5
3. Bentéjac C., Csörgő A., & Martínez-Muñoz G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937-1967
4. Bhatnagar R., & Gohain G. B. (2020). Crop yield estimation using decision trees and Random Forest machine learning algorithms on data from terra (EOS AM-1) & Aqua (EOS PM-1) satellite data. *Machine Learning and Data Mining in Aerospace Technology*, 107-124
5. Biau G. (2012). Analysis of a Random Forests model. *The Journal of Machine Learning Research*, 13(1), 1063-1095
6. Biau G., & Scornet E. (2016). A Random Forest guided tour. *Test*, 25, 197-227
7. Boztosun D., Aksoylu S., & Ulucak, Z. Ş. (2016). The role of human capital in economic growth. *Economics World*, 4(3), 101-110
8. Breiman L. (2001). Random Forests. *Machine Learning*, 45, 5-32
9. Briganti G., & Le Monie O. (2020). Artificial Intelligence in Medicine: Today and Tomorrow. *Frontiers in Medicine*, (7)27

10. Brown, R. (2019). Evaluating Market Conditions in Real Estate Valuation. *Real Estate Appraisal Journal*, 56(2), 75-88.
11. Brown, R. (2019). The Role of IA in Modern Real Estate Markets. *Real Estate Economics*, 48(2), 123-140.
12. Brown, R. (2020). Understanding Automated Valuation Models in Real Estate. *Real Estate Appraisal Journal*, 58(1), 90-104.
13. Büyükkaracıoğlu D. N. (2021). Modern methods approach in real estate valuation. *Ankara: Iksad Publishing House*, 130
14. Carmona P., Climent F., & Momparler A. (2019). Predicting failure in the US banking sector: An extreme gradient boosting approach. *International Review of Economics & Finance*, 61, 304-323
15. Chen T., He T., Benesty M., Khotilovich V., Tang Y., Cho H., ... & Zhou T. (2015). XGboost: extreme gradient boosting. *R package version 0.4-2*, 1(4), 1-4
16. Choudhury M. (2015). Subjective probability and financial valuation: contrasting paradigms. *Journal of Financial Reporting and Accounting*, 13(1), 20-38
17. Dash S. (2022). Decision Trees Explained – Entropy, Information Gain, Gini Index, CCP Pruning. *Towards Data Science*, 46
18. Davis, M. & Taylor, S. (2022). The Intersection of Valuation and Audit in Financial Reporting. *Journal of Accounting and Economics*, 60(3), 215-230.
19. Davis, M., & Williams, K. (2022). Transparency in Fair Value Reporting: The Role of IA-Based Valuations. *International Journal of Financial Reporting*, 29(3), 150-167.
20. Ding S., Li H., Su C., Yu J., & Jin F. (2013). Evolutionary artificial neural networks: a review. *Artificial Intelligence Review*, 39, 251-260
21. Dongare A. D., Kharde R. R., & Kachare A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194
22. Drahokoupil J. (2022). Application of the XGBoost algorithm and Bayesian optimization for the Bitcoin price prediction during the COVID-19 period. *FFA Working Papers*
23. Ferrari R. (2015). Writing narrative style literature reviews. *Medical writing*, 24(4), 230-235
24. Ge Y., & Wu H. (2020). Prediction of corn price fluctuation based on multiple linear regression analysis model under big data. *Neural Computing and Applications*, 32, 16843-16855
25. Ghosh A., & Maiti R. (2021). Soil erosion susceptibility assessment using logistic regression, decision tree and Random Forest: study on the Mayurakshi river basin of Eastern India. *Environmental Earth Sciences*, 80(8), 328
26. González C., Mira J. M., & Ojeda J. A. (2016). Applying multi-output Random Forest models to electricity price forecast. *Statistical Laboratory, Technical University of Madrid*
27. Goundar S., Maharaj K., Kumar A., & Bhardwaj A. (2021). Property valuation using linear regression and Random Forest algorithm. *International Journal of System Dynamics Applications (IJSDA)*, 10(4), 1-16
28. Gupta B., Rawat A., Jain A., Arora A., & Dhama N. (2017). Analysis of various decision tree algorithms for classification in data mining. *International Journal of Computer Applications*, 163(8), 15-19
29. Heinze G., Wallisch C., & Dunkler D. (2018). Variable selection—a review and recommendations for the practicing statistician. *Biometrical journal*, 60(3), 431-449
30. Hengl T., Nussbaum M., Wright M. N., Heuvelink G. B., & Gräler B. (2018). Random Forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, 6, e5518
31. Hodson T. O. (2022). Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, 2022, 1-10
32. Huang J., Saleh S., & Liu Y. (2021). A Review on Artificial Intelligence in Education. *Academic Journal of Interdisciplinary Studies*, 10(3). 207-217
33. Jadhav S. D., & Channe H. P. (2016). Comparative study of K-NN, naive Bayes and decision tree classification techniques. *International Journal of Science and Research (IJSR)*, 5(1), 1842-1845
34. James G., Witten D., Hastie T., & Tibshirani R. (2013). An introduction to statistical learning (Vol. 112, p. 18). *New York: Springer*.
35. James G., Witten D., Hastie T., Tibshirani R., & Taylor J. (2023). Linear regression. In An

- introduction to statistical learning: With applications in python. *Springer International Publishing*, 69-134
36. Johnson, L. & Williams, K. (2021). Financial Reporting and the Role of Fair Value in Real Estate. *International Journal of Financial Auditing*, 33(4), 589-603.
 37. Johnson, L. & Williams, K. (2021). Machine Learning in Real Estate: Implications for Auditors. *International Journal of Financial Auditing*, 32(4), 567-580.
 38. Jha, G. K., & Sinha, K. (2013). Agricultural price forecasting using neural network model: An innovative information delivery system. *Agricultural Economics Research Review*, 26(2), 229-240
 39. Khaidem L., Saha S., & Dey S. R. (2016). Predicting the direction of stock market prices using Random Forest. *arXiv preprint arXiv:1605.00003*.
 40. Khalilov D. A., Jumaboyeva N. A. K., & Kurbonova T. M. K. (2021). Advantages and Applications of Neural Networks. *Academic research in educational sciences*, 2(2), 1153-1159
 41. Khan Z. (2022). Used car price evaluation using three different variants of linear regression. *International Journal of Computational and Innovative Sciences*, 1(1), 12-20
 42. Khan Z. H., Alin, T. S., & Hussain, M. A. (2011). Price prediction of share market using artificial neural network (ANN). *International Journal of Computer Applications*, 22(2), 42-47
 43. Khanzode K. C. A., & Sarode R. D. (2020). Advantages and disadvantages of artificial intelligence and machine learning: A literature review. *International Journal of Library & Information Science (IJLIS)*, 9(1), 3
 44. Korkmaz M. (2021). A study over the general formula of regression sum of squares in multiple linear regression. *Numerical Methods for Partial Differential Equations*, 37(1), 406-421
 45. Krenker A., Bešter J., & Kos A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech*, 1-18
 46. Langsetmo L., Schousboe J. T., Taylor B. C., Cauley J. A., Fink H. A., Cawthon, P. M., ... & Osteoporotic Fractures in Men (MrOS) Research Group. (2023). Advantages and disadvantages of Random Forest models for prediction of hip fracture risk versus mortality risk in the oldest old. *Journal of Bone and Mineral Research Plus*, 7(8)
 47. Lasota T., Łuczak, T. Niemczyk M., Olszewski M., & Trawiński B. (2013). Investigation of property valuation models based on decision tree ensembles built over noised data. In *Computational Collective Intelligence. Technologies and Applications: 5th International Conference, ICCCI 2013, Craiova, Romania, September 11-13, 2013, Proceedings 5* (pp. 417-426). Springer Berlin Heidelberg
 48. Ma B., Meng, F., Yan G., Yan H., Chai B., & Song F. (2020). Diagnostic classification of cancers using extreme gradient boosting algorithm and multi-omics data. *Computers in biology and medicine*, 121
 49. Manoj, J., & Suresh, K. K. (2019). Forecast model for price of gold: Multiple linear regression with principal component analysis. *Thailand Statistician*, 17(1), 125-131
 50. Mombeini H., & Yazdani-Chamzini A. (2015). Modeling gold price via artificial neural network. *Journal of Economics, business and Management*, 3(7), 699-703
 51. Mohammad S. J., Hamad A. K., Borgi H., Thu P. A., Sial M. S., & Alhadidi A. A. (2020). How artificial intelligence changes the future of accounting industry. *International Journal of Economics and Business Administration*, 8(3), 478-488
 52. NandigalaVenkatAnurag, Y., & Sharanya, S. (2019). Air Quality Index Prediction with Meteorological Data Using Feature Based Weighted Xgboost. *International Journal of Recent Technology and Engineering (IJRTE)*, 8(1), 1355-1358.
 53. Nikolaev D., & Petrova M. (2021, October). Application of simple convolutional neural networks in equity price estimation. In *2021 IEEE 8th International Conference on Problems of Infocommunications, Science and Technology (PIC S&T)*, pp. 147-150
 54. Nwulu, N. I. (2017, September). A decision trees approach to oil price prediction. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, pp. 1-5
 55. Oba, K. M. (2019). A multiple linear regression model to predict the price of cement in Nigeria. *International journal of economics and management engineering*, 13(12), 1480-1485

56. Oshiro T. M., Perez P. S., & Baranauskas J. A. (2012). How many trees in a Random Forest?. In *Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012*, Berlin, Germany, July 13-20, 2012. Proceedings 8 (pp. 154-168). Springer Berlin Heidelberg
57. Osman A. I. A., Ahmed A. N., Chow M. F., Huang Y. F., & El-Shafie A. (2021). Extreme gradient boosting (Xgboost) model to predict the groundwater levels in Selangor Malaysia. *Ain Shams Engineering Journal*, 12(2), 1545-1556
58. Padmanaban, K. A., & Parthiban, G. (2016). Applying machine learning techniques for predicting the risk of chronic kidney disease. *Indian Journal of Science and Technology*, 9(29), 1-6
59. Pannu A. (2015). Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10), 79-84
60. Patel, A. (2023). Integrating IA with Traditional Real Estate Valuation Techniques. *Global Real Estate Journal*, 29(5), 345-362.
61. Pekel E. (2020). Estimation of soil moisture using decision tree regression. *Theoretical and Applied Climatology*, 139(3), 1111-1119
62. Prajwala T. R. (2015). A comparative study on decision tree and Random Forest using R tool. *International journal of advanced research in computer and communication engineering*, 4(1), 196-199
63. Putra P. H., Azanuddin A., Purba B., & Dalimunthe Y. A. (2023). Random Forest and decision tree algorithms for car price prediction. *Jurnal Matematika Dan Ilmu Pengetahuan Alam LLDikti Wilayah 1 (JUMPA)*, 3(2), 81-89
64. Ramani K., Jahnavi M., Reddy P. J., VenkataChakravarthi, P., Meghanath P., & Imran S. K. (2023, March). Prediction of bitcoin price through LSTM, ARIMA, XGBoost, prophet and sentiment analysis on dynamic streaming data. In *2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS)* (Vol. 1, pp. 1514-1518)
65. Rousseeuw P. J., & Leroy A. M. (2005). Robust regression and outlier detection. *John wiley & Sons*
66. Roy, S. S., Mittal, D., Basu, A., & Abraham, A. (2015). Stock market forecasting using LASSO linear regression model. In *Afro-European Conference for Industrial Advancement: Proceedings of the First International Afro-European Conference for Industrial Advancement AECIA 2014* (pp. 371-381)
67. Saini, D., Saxena, A., & Bansal, R. C. (2016, December). Electricity price forecasting by linear regression and SVM. In *2016 International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*, pp. 1-7
68. Shaik A. B., & Srinivasan S. (2019). A brief survey on Random Forest ensembles in classification model. In *International Conference on Innovative Computing and Communications: Proceedings of ICICC 2018*, Volume 2, pp. 253-260
69. Shanbehzadeh, M., Nopour, R., & Kazemi-Arpanahi, H. (2022). Design of an artificial neural network to predict mortality among COVID-19 patients. *Informatics in medicine unlocked*, 31
70. Shilong Z. (2021). Machine learning model for sales forecasting by using XGBoost. In *2021 IEEE international conference on consumer electronics and computer engineering*, pp. 480-483
71. Sisodia D., & Sisodia D. S. (2018). Prediction of diabetes using classification algorithms. *Procedia computer science*, 132, 1578-1585
72. Smith, J. (2020). IA and Real Estate: The Future of Property Valuation. *Journal of Real Estate Research*, 45(3), 221-234.
73. Smith, J. (2020). Theoretical Foundations of Property Valuation. *Journal of Real Estate Economics*, 42(1), 112-129.
74. Svetlana N., Anna N., Svetlana M., Tatiana G., & Olga M. (2022). Artificial intelligence as a driver of business process transformation. *Procedia Computer Science*, 213, 276-284.
75. Suthaharan S. (2016). Decision tree learning. *Machine Learning Models and Algorithms for Big Data Classification: Thinking with Examples for Effective Learning*, *Integrated Series in Information Systems*, 36, 237-269
76. Şipoş C., Crivii E. A., & FRICS M. (2008). A linear regression model for real estate appraisal. In *WAVO Valuation Congress Valuation in Diversified and Emerging Economies*, pp. 17-18
77. Taylor, S. (2023). Ensuring Accuracy in IA-Driven Valuations for Financial Reporting. *Journal of Accounting and Economics*, 62(1), 35-50.

78. Vaiz J. S., & Ramaswami M. (2016). A study on technical indicators in stock price movement prediction using decision tree algorithms. *American Journal of Engineering Research (AJER)*, 5(12), 207-12
79. Ugurlu U., Oksuz I., & Tas O. (2018). Electricity price forecasting using recurrent neural networks. *Energies*, 11(5), 1255
80. Vuong P. H., Dat T. T., Mai T. K., & Uyen P. H. (2022). Stock-price forecasting based on XGBoost and LSTM. *Computer Systems Science & Engineering*, 40(1)
81. Wang S. C. (2003). Artificial neural network. *Interdisciplinary computing in java programming*, 81-100
82. Wu Y. C., & Feng J. W. (2018). Development and application of artificial neural network. *Wireless Personal Communications*, 102, 1645-1656
83. Ya, K., Li W., Ji Z., Qi M., & Du Y. (2019). A hybrid LSTM neural network for energy consumption forecasting of individual households. *Ieee Access*, 7, 157633-157642
84. Zhang Z., (2018). Artificial neural network. *Multivariate time series analysis in climate and environmental research*, 1-35
85. Zou J., Han Y., & So S. S. (2009). Overview of artificial neural networks. *Artificial neural networks: methods and applications*, 14-22
86. Zhou J., Qiu Y., Zhu S., & Jahed D. (2021). Estimation of the TBM advance rate under hard rock conditions using XGBoost and Bayesian optimization. *Underground Space*, 6(5), 506-515
87. Zhou, L., Pan S., Wang J., & Vasilakos A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237, 350-361
88. Zhou Y., Li, T., Shi J., & Qian Z. (2019). A CEEMDAN and XGBOOST-based approach to forecast crude oil prices. *Complexity*, 2019(1)
89. Zhou T., Shi P., Jia G., & Luo Y. (2013). Nonsteady state carbon sequestration in forest ecosystems of China estimated by data assimilation. *Journal of Geophysical Research: Biogeosciences*, 118(4), 1369-1384