

MACHINE LEARNING ȘI MANAGEMENTUL REZULTATELOR: O RECENZIE A LITERATURII

MACHINE LEARNING AND EARNINGS MANAGEMENT: A LITERATURE REVIEW

IORDACHE Eusebiu

Alexandru Ioan Cuza University of Iași, România

E-mail: eusebiu.jordache@gmail.com

Abstract. Odată cu răspândirea inteligenței artificiale, tehnologia de machine learning s-a dezvoltat ca un mecanism complementar prin care sistemele sunt instruite să gestioneze datele în mod eficient, fără a fi programate explicit pentru fiecare sarcină. Practicile contabile și de audit pot beneficia de funcționalitățile oferite de machine learning, deoarece, comparativ cu modelele statistice tradiționale, acestea utilizează tehnici complexe, precum data mining, cu scopul de a extrage informații suplimentare din baze de date extinse. Un fenomen întâlnit în raportarea financiară, și la detectarea căruia pot fi utilizate tehnicile de machine learning, este managementul rezultatelor. Aceste tehnologii se pot dovedi eficiente în detectarea practicilor de management al rezultatelor prin prisma algoritmilor de învățare care extrag date și sintetizează reguli și tipare din seturi de date utilizate în antrenare și care sunt mai apoi utilizate asupra unor seturi de date noi, necunoscute.

Scopul acestui studiu este de a evidenția nivelul actual al cunoașterii din literatură privind utilizarea tehnologiei machine learning în detectarea practicilor de management al rezultatelor. În acest sens, analiza include studii care cercetează utilitatea progreselor din domeniul inteligenței artificiale în prognozarea managementului rezultatelor și care evaluează eficiența practică a acestei tehnologii în comparație cu modelele statistice tradiționale. O limitare importantă a acestei cercetări este caracterul relativ nou al temei analizate și rapiditatea dezvoltării noilor tehnologii de machine learning.

Keywords: artificial intelligence, machine learning, earnings management, financial reporting

JEL Classification: M41, C55, O33

Introducere

Un fenomen studiat în literatură și întâlnit în practică este cel al managementului rezultatelor (earnings management), ca element prin care se măsoară calitatea contabilității și a raportărilor financiare. În unele articole se afirmă faptul că gestionarea rezultatelor are loc atunci când managerii folosesc raționamentul în raportarea financiară și în structurarea tranzacțiilor pentru a modifica rapoartele financiare cu scopul de a induce în eroare unele părți interesate (stakeholderii) cu privire la performanța economică sau pentru a influența o serie de clauze contractuale care depind de cifrele contabile raportate (Healy & Wahlen, 1999). Astfel, această practică este întreprinsă de acțiunea managerului pentru a gestiona rezultatele companiei cu scopul de a atinge anumite obiective sau interese (Purwanti & Utama, 2018).

Managementul rezultatelor, într-o definiție simplistă care nu scoate în evidență înțelesul negativ al conceptului, reprezintă un proces de alegere a alternativelor contabile în vederea obținerii rezultatelor contabile dorite (Istrate et al., 2015). Astfel, din punct de vedere conceptual, managementul rezultatelor reprezintă o metodă care poate sprijini creșterea valorii entității și îi poate asigura continuitate, dacă este folosită în mod etic. Or, unii autori (Dechow & Skinner, 2000) susțin faptul că lipsa managementului rezultatelor nu este o variantă optimă, aceasta fiind o practică previzibilă și necesară în piața de capital. Prin urmare, cu toate că această practică poate genera efecte similare unei fraude, caracterizată prin încălcarea reglementărilor contabile, managementul rezultatelor poate avea loc din pricina limitelor acestor norme (Istrate et al., 2015).

Având în vedere că părțile interesate ale unei întreprinderi nu pot observa în mod direct performanța operațională a acesteia, rezultatele raportate sunt considerate adesea un indicator relevant al performanței companiei, iar managementul rezultatelor a devenit un stimulent important pentru deciziile luate de către conducere (Chen et al., 2015). Cu toate acestea, atunci când practicile de management al rezultatelor devin frecvente, utilizatorii situațiilor financiare pot dezvolta percepții eronate asupra performanței reale a companiei, ceea ce poate conduce la adoptarea unor decizii economice care se pot dovedi neinspirate (Chen et al., 2015).

Machine learning (ML) este una dintre aplicațiile de inteligență artificială care permite sistemelor să învețe și să progreseze în mod automat, fără a fi codificate explicit (Almaqtari et al., 2021). Principalul obiectiv al machine learningului este de a concepe un algoritm care ar putea învăța cum să îndeplinească sarcini prin generalizarea informațiilor obținute din exemple (Dbouk & Zaarour, 2017). În literatură, în ceea ce privește detectarea, analiza și predicția managementului rezultatelor, accentul este pus pe identificarea fenomenului prin abordări statistice tradiționale, dar acestea au unele impedimente privind ipotezele, cum ar fi liniaritatea, normalitatea și independența variabilelor (Chen & Howard, 2015). Aceste condiții sunt frecvent încălcate în cazul datelor financiare, ceea ce poate reduce eficiența și validitatea acestor metode (Chen et al., 2015). În comparație, abordările ale data miningului, precum arborele decizional (decision tree – DT) sunt mai puțin vulnerabile la limitările metodelor clasice.

În ultimii ani au fost dezvoltate tehnici de inteligență artificială și data mining care și-au găsit aplicabilitatea în economie, și în mod implicit în domeniul contabil. Pe baza dezvoltării acestora, tehnologia de machine learning a devenit din ce în ce mai eficientă în vederea gestionării bazelor mari de date financiare. (Chen & Howard, 2015). Această eficiență se datorează mecanismului prin care funcționează machine learningul, respectiv prin urmărirea de a identifica corelații și modele noi, valide, folositoare și inteligibile în datele financiare care sunt folosite în detectarea practicii de earnings managements (Chen & Howard, 2015).

Managerii nu doresc ca acțiunile lor de gestiune a rezultatelor să fie descoperite pentru că pot afecta reputația acestora și poate duce la scăderea încrederii oferite de stakeholderi. Astfel, managerii vor apela la o varietate de tehnici pentru a gestiona rezultatele, respectiv vor folosi metode, care se vor schimba în timp, de a ascunde această practică, fapte care dau caracteristicile neliniare complexe ale managementului rezultatelor (Li & Sun, 2023).

Potrivit unor autori, modelele de identificare a acțiunilor de earnings management nu sunt modele simple liniare, acest lucru favorizând aplicarea tehnicii de machine learning (Chen & Shen, 2020). Obiectivul acestei lucrări este de a recenza literatura în vederea cercetării metodelor de machine learning folosite pentru a detecta, analiza și a prezice practica de earnings management.

Întrebările de cercetare, care stau la baza atingerii obiectivului propus sunt:

1. Cum este folosit machine learningul în cercetarea practicii de gestiune a rezultatelor?
2. Care sunt principalele modele de machine learning aplicate în relație cu earnings management?
3. Care sunt limitările aplicării ML în relație cu EM?

1. Cum este folosit machine learningul în cercetarea practicii de gestiune a rezultatelor?

Studiile regăsite în literatură arată faptul că tehnicile de data mining au o capacitate mai bună de detectare și predicție a practicilor de earnings management în comparație cu metodele statistice tradiționale (Li & Sun, 2023). Pe baza algoritmului de învățare, tehnologia de deep learning (componentă a machine learning) face ca modelul să învețe automat o reprezentare bună a datelor, ca mai apoi să transforme datele noi introduse și să le abstractizeze, astfel încât să se îmbunătățească precizia de predicție a modelului (Li & Sun, 2023).

Tehnologia de machine learning poate contribui semnificativ la creșterea acurateței și eficienței în identificarea fenomenului de earnings management, prin realizarea unor profiluri financiare ale companiilor care caracterizează strategiile, respectiv ascendente și descendente, și instrumentele folosite, respectiv accruals, real activities și clasification shifting (Veganzones & Séverin, 2025). Astfel, machine learning poate reprezenta o bază solidă pentru luarea deciziilor de către auditori și stakeholderi.

Pe baza analizei relațiilor nonliniare, modelele bazate pe rețele neuronale (neural networks) ar putea determina total accruals (provizioane și ajustări totale), discretionary accruals (provizioane și ajustări discreționare) și non-discretionary accruals (provizioane și ajustări non-discreționare), care sunt utilizate în mod uzual ca proxy pentru earnings management (Höglund, 2012).

Studiul realizat de Almasarwah et al. (2024) urmărește identificare unor noi componente financiare implicate în managementul rezultatelor prin aplicarea tehnicilor de machine learning. Astfel, cu ajutorul algoritmului XGBoost, autorii au identificat nouă potențiale variabile financiare care pot fi utilizate în gestiunea rezultatelor, cele mai mari ponderi fiind înregistrate de costul bunurilor vândute, cu o importanță de 40,2% și indicatorul EBITDA cu o pondere de 11,5% (Almasarwah et al., 2014). Prin identificarea unor practici semnificative de ajustare a performanței raportate, tehnicile moderne de machine learning pot oferi o perspectivă mai amplă asupra fenomenului de earnings management și pot juca un rol important în detectarea acestuia.

Tehnologia de machine learning își găsește aplicabilitatea și în predicția fenomenului de earnings management, deși întâmpină dificultăți în previziunea prin activități reale (real earnings management) în comparație cu forma bazată pe ajustări și provizioane (accruals earnings management) (Hammami & Hendikani Zadeh, 2022).

2. Care sunt principalele modele de machine learning aplicate în relație cu earnings management?

Algoritmii machine learning sunt adesea clasificați în patru categorii principale: supervizați (supervised), semi-supervizați (hybrid), nesupervizați (unsupervised) și algoritmi de învățare prin întărire (reinforcement learning algorithms). Cu toate că învățarea nesupravegheată este considerată mult mai apropiată de inteligența artificială deoarece algoritmul poate determina procesele complexe din cadrul datelor fără prea multe îndrumări externe (Rahul et al., 2018), în detectarea tehnicii de earnings management cea mai folosită este învățarea supravegheată (Almaqtari et al., 2021).

Numeroase metode de machine learning sunt aduse în discuție în literatură și sunt testate pentru a cerceta eficiența acestora în detectarea și predicția tehnicii de gestionare a rezultatelor, precum Rețeaua Bayesiană (Bayesian Network – BN), Analiza Componentelor Principale (Principal Components Analysis – PCA), algoritmul arbore de decizie C5.0, Rețeaua Neuronală cu Propagare Inversă (Back Propagation Neural Network – BPNN) etc. (Almaqtari, 2021).

În literatură, unele studii au utilizat tehnici de data mining pentru detectarea practicilor de management al câștigurilor, avantajul acestei metode fiind reprezentat de capacitatea de a construi modele neliniare, care nu necesită formularea unor ipoteze restrictive, așa cum se întâmplă în cazul metodelor statistice convenționale (Chen et al., 2015).

Chen et al. (2015) au ajuns la concluzia, conform rezultatelor empirice, că integrarea rețelelor Bayesiene cu algoritmul arborelui de decizie C5.0 conduce la cea mai bună performanță în detectarea unui nivel ridicat de gestiune a rezultatelor prin accruals (provizioane și ajustări), acuratețea datelor testate atingând nivelul de 98,51% și rata erorii de tip 1 fiind, de asemenea, cea mai redusă.

Modelele bazate pe arbori de decizie prezintă mai multe avantaje în detectarea managementului rezultatelor precum lipsa necesității de ipoteze statistice privind distribuția datelor utilizate în etapa de antrenare și gestionarea atât a datelor incomplete, cât și a variabilelor calitative (Chen et al., 2015). Totodată, aceste modele oferă o reprezentare intuitivă a cunoștințelor extrase din date, iar interpretarea acestora este facilă, fiind exprimate sub formă de reguli binare (Chen et al., 2015).

Rahul et al. (2018) au propus o abordare pentru detectarea și predicția practicii de accruals earnings management utilizând modele de învățare automată supravegheată de tip ansamblu și totodată, au dezvoltat un model de învățare automată nesupravegheată, fundamentat pe detectarea anomaliilor Gaussiane, cu o acuratețe de 71,68%.

În comparație cu detectarea practicilor de earnings management, studiile privind predicția acestora sunt limitate (Kang & Park, 2021). Rezultatele obținute de Tsai & Chiou (2009) au arătat că modelul de rețea neuronală de tip MLP poate atinge o rată de acuratețe de 81,08% în predicția cazurilor de manipulare ascendentă a rezultatelor, iar prin utilizarea arborilor de decizie a fost posibilă identificarea unor reguli relevante de clasificare, caracterizate prin cel mai ridicat nivel de acuratețe.

În cazul studiului întreprins de Mahmoudi et al. (2017), rezultatele obținute arată faptul că rețeaua neuronală MLP, cu două straturi ascunse, este capabilă să prezică managementul rezultatelor în mai multe industrii, cu o acuratețe maximă de 81% în industria produselor chimice și minimă de 57% în industria produselor nemetalice. Totodată, modelul de rețea neuronală MLP poate oferi o rată de acuratețe a predicției acțiunii de management al rezultatelor de 54,25%, în cazul industriei de electronice. (Tsai & Chiou, 2009).

Cu toate că rețelele neuronale sunt adesea criticate pentru capacitatea limitată de interpretare a rezultatelor și pentru dificultățile legate de alegerea arhitecturii modelului, acestea prezintă avantaje importante precum faptul că acestea pot modela relații complexe și neliniare între variabile, respectiv sunt flexibile și pot gestiona eficient seturi de date incomplete, lipsă sau afectate de zgomot (Tsai & Chiou, 2009).

Tehnica de machine learning, precum procesarea limbajului natural (Natural Language Processing – NLP), poate fi utilizată pentru a extrage date de bază suplimentare, de natură calitativă (Xu, 2020), care pot fi folosite în interpretarea informațiilor din situațiile financiare (Almaqtari et al., 2021). Datele calitative, precum informațiile privind litigiile în care este implicată compania oferă performanțe mai bune în ceea ce privește predicția tehnicii de earnings management cu ajutorul tehnologiei de machine learning (Kang et al., 2024).

În literatură se remarcă faptul că modelele hibride (Bayesian network + C5.0; Bayesian network + Back propagation neural networks; Principal component analysis + Back propagation neural networks; Principal component analysis + C5.0) oferă performanțe superioare și stabilitate ridicată, fiind optime din perspectiva acurateței, a erorilor de tip I și a variabilelor predictive utilizate (Chen et al., 2015). Cu atât mai mult cu cât modelul hibrid Bayesian network + C5.0, comparativ cu alte metode, prezintă rezultate mai bune atât în ceea ce privește acuratețea predicției, cât și selecția variabilelor relevante. (Chen et al., 2015).

3. Care sunt limitările aplicării ML în relație cu EM?

Cu toate că machine learningul oferă numeroase avantaje, utilizarea acestor tehnologii implică și anumite provocări, printre care se numără aspecte etice și necesitatea respectării cerințelor de reglementare (Bojuwon et al., 2026).

Complexitatea modelelor de machine learning poate reduce transparența procesului decizional, deoarece mecanismele prin care acestea generează predicții sunt adesea dificil de interpretat, iar această situație poate conduce la o dependență excesivă de sistemele automatizate și poate afecta capacitatea practicienilor de a evalua critic rezultatele generate de algoritmi (Munoko et al., 2020).

Un alt aspect frecvent asociat cu tehnicile de machine learning, în special cu rețelele neuronale, este riscul de supraantrenare (overtraining), care apare atunci când modelul învață prea bine caracteristicile datelor de antrenare și își pierde capacitatea de generalizare pentru date noi (Tsai & Chiou, 2009). Totodată, o altă limitare importantă este dată de dificultatea de a explica modul în care aceste modele generează rezultatele, ceea ce limitează transparența procesului decizional (Tsai & Chiou, 2009).

Managementul real al rezultatelor este mai greu de detectat decât managementul prin provizioane și ajustări, iar astfel metodologia bazată pe tehnologia AI se confruntă cu limitări în detectarea sau predicția gestionării reale a rezultatelor (Kang & Park, 2021). Această limitare este cu atât mai relevantă cu cât studiile care analizează managementul real al rezultatelor evidențiază caracterul răspândit al acestei practici cu scopul de a influența câștigurile pe termen scurt, chiar dacă aceste acțiuni pot compromite performanța economică pe termen lung (Braswell & Daniels, 2017; Graham et al., 2005).

Cu toate că modele de tip hibrid, precum Random Forest și C5.0, pot oferi performanțe suplimentare în detectarea fenomenului de earnings management, acestea au și o serie de limitări importante. În funcție de tehnica aplicată, performanța și relevanța predictorilor pot varia datorită sensibilității rezultatelor la metoda de selecție a variabilelor utilizată (Chen & Howard, 2015). Totodată, o a doua limitare constă în cea temporală, atunci când sunt folosite date financiare pe o perioadă scurtă de timp, în timp ce pot fi omise tendințe care evoluează și sunt vizibile pe termen lung (Chen & Howard, 2015).

O altă limitare a tehnologiei de machine learning o reprezintă datele necesare de analizat ale algoritmului. Performanța algoritmilor depinde, în mare măsură, de calitatea datelor utilizate pentru antrenarea acestora, iar seturile de date incomplete sau dezechilibrate pot genera rezultate distorsionate (Munoko et al., 2020). Fenomenul de earnings management este unul ascuns, ceea ce rezultă din dificultatea etichetării obiective în baza de date, învățarea supervizată (supervised learning) bazându-se pe etichetarea corectă. Totodată, datele care au fost supuse metodelor de gestionare a rezultatelor sunt mai rare comparativ cu cele care nu au fost supuse unor astfel de practici, rezultând astfel dificultatea algoritmului de a se antrena, ceea ce poate duce la rezultate eronate.

Concluzii

Odată cu dezvoltarea tehnologică care influențează domeniul contabil, aplicarea tehnicilor de machine learning în identificarea și predicția managementului rezultatelor se dovedește a fi un subiect de cercetare relevant. Recenzarea literaturii realizate în cadrul acestei lucrări evidențiază beneficiile aduse de capacitatea machine learning de a gestiona baze mari de date financiare, care pot contrabalansa limitările modelelor liniare tradiționale, și care au ca rezultat o creștere a eficienței și acurateței în identificarea practicilor de gestionare a rezultatelor.

Studiile cercetate analizează o varietate de algoritmi de machine learning precum Rețeaua Bayesiană, Analiza Componentelor Principale, algoritmul arbore de decizie C5.0, Rețeaua Neuronală cu Propagare Inversă. Acestea indică niveluri ridicate de acuratețe în ceea ce privește detectarea practicilor de earnings management, cu o pondere de până la 98%. Cu toate acestea, în ceea ce privește predicția acestor practici, din cauza caracteristicilor și împrejurărilor în care au loc, rezultatele sunt inferioare și fluctuează considerabil în funcție de sectorul de activitate, înregistrând ponderi de la 50, până la 80%.

Cu toate că tehnologia de machine learning reprezintă un avantaj semnificativ în relația cu fenomenul de earnings management, aceasta nu este lipsită de limitări. În funcție de algoritmi și tehnicile aplicate, rezultatele pot prezenta fluctuații, iar pe baza perioadei analizate, pot fi omise tendințe ce sunt vizibile și evoluează pe termen lung.

Astfel, tehnica de machine learning evoluează odată cu dezvoltarea tehnologiei și cu cercetarea acestei practici în relație cu domeniul contabil și totodată acționează ca un instrument complementar al raționamentului profesional, ce are ca scop susținerea în detectarea și predicția fenomenului de earnings management.

References

1. Almaqtari, F. A., Farhan, N. H. S., Salmony, M. Y., Al-Ahdal, W. M., & Mishra, N. (2021). Earning management estimation and prediction using machine learning: A systematic review of processing methods and synthesis for future research. 2021 International Conference on Technological Advancements and Innovations (ICTAI), 291–298. <https://doi.org/10.1109/ICTAI53825.2021.9673157>
2. Almasarwah, A., Aram, K. Y., & Alhaj-Yaseen, Y. S. (2024). Identifying new earnings management components: A machine learning approach. *Accounting Research Journal*, 37(4), 418–435. <https://doi.org/10.1108/arj-10-2023-0304>
3. Bojuwon, M., Aduwo, A. E., Adebayo, A. I., Olasehinde S. A., Aduwo, O. O., Adekanmi, A. D., Owoniya, B., Dinatu, N. A., Ajewole A. S. (2026). Artificial Intelligence and Corporate Earnings Management. *Advances in Artificial Intelligence and Machine Learning*, 06(02), 01–18. <https://doi.org/10.54364/AAIML.2026.62285>
4. Braswell, M., & Daniels, R. B. (2017). Alternative Earnings Management Techniques: What Audit Committees and Internal Auditors Should Know. *Journal of Corporate Accounting & Finance*, 28(2), 45–54. <https://doi.org/10.1002/jcaf.22239>
5. Chen, F.-H., & Howard, H. (2015). An alternative model for the analysis of detecting electronic industries earnings management using stepwise regression, random forest, and decision tree. *Soft Computing*, 20(5), 1945–1960. <https://doi.org/10.1007/s00500-015-1616-6>
6. Chen, F.-H., Chi, D.-J., & Wang, Y.-C. (2015). Detecting biotechnology industry's earnings management using Bayesian network, principal component analysis, back propagation neural network, and decision tree. *Economic Modelling*, 46, 1–10. <https://doi.org/10.1016/j.econmod.2014.12.035>

7. Chen, S., & Shen, Z.-D. (2020). An Effective Enterprise Earnings Management Detection Model for Capital Market Development. *Journal of Economics, Management and Trade*, 77–91. <https://doi.org/10.9734/jemt/2020/v26i430250>
8. Dbouk, B., & Zaarour, I. (2017). Towards a Machine Learning Approach for Earnings Manipulation Detection, *Asian Journal of Business and Accounting*, 10(2).
9. Dechow, P. M., & Skinner, D. J. (2000). Earnings Management: Reconciling the Views of Accounting Academics, Practitioners, and Regulators. *Accounting Horizons*, 14(2), 235-250
10. Graham, J. R., Harvey, C. R., & Rajgopal, S. (2005). The economic implications of corporate financial reporting. *Journal of Accounting and Economics*, 40(1–3), 3–73. <https://doi.org/10.1016/j.jacceco.2005.01.002>
11. Hammami, A., & Hendijani Zadeh, M. (2022). Predicting earnings management through machine learning ensemble classifiers. *Journal of Forecasting*, 41(8), 1639–1660. <https://doi.org/10.1002/for.2885>
12. Healy, P. M., & Wahlen, J. M. (1999). A Review of the Earnings Management Literature and its Implications for Standard Setting. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.156445>
13. Höglund, H. (2012). Detecting earnings management with neural networks. *Expert Systems with Applications*, 39(10), 9564–9570. <https://doi.org/10.1016/j.eswa.2012.02.096>
14. Istrate, C., Georgescu, I., Carp, M., Robu, I. B., Pavaloaia, L. (2015). Accruals earnings management in emerging markets under the transition to IFRS: The case of Romanian listed companies. *Transformations in Business and Economics*, vol 14, 393-411.
15. Kang, H., Kim, H., & Na, H. J. (2024). A Study on the Forecast of Earning Management Based on Deep Learning by Reflecting Information on Corporate Litigation Cases. *IEEE Access*, 12, 139097–139112. <https://doi.org/10.1109/ACCESS.2024.3458929>
16. Kang, S., & Park, S. (2021). Artificial Intelligence-based Detection and Prediction of Corporate Earnings Management. In P. M. S. Choi & S. H. Huang (Ed.), *Fintech with Artificial Intelligence, Big Data, and Blockchain* (pp. 191–203). Springer Singapore. https://doi.org/10.1007/978-981-33-6137-9_8
17. Li, J., & Sun, Z. (2023). Application of deep learning in recognition of accrued earnings management. *Heliyon*, 9(3), e13664. <https://doi.org/10.1016/j.heliyon.2023.e13664>
18. Mahmoudi, S., Mahmoudi, S., & Mahmoudi, A. (2017). Prediction Of Earnings Management By Use Of Multi- Layer Perceptron Neural Networks With Two Hidden Layers In Various Industries, *Journal of Entrepreneurship, Business and Economics*, 5(1), 216-236
19. Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. (2020). The Ethical Implications of Using Artificial Intelligence in Auditing. *Journal of Business Ethics*, 167(2), 209–234. <https://doi.org/10.1007/s10551-019-04407-1>
20. Purwanti, A., Utama, I. W. W. (2019). Earning Management Analysis before and after Implementation of International Financial Reporting Standards (IFRS): Empirical Study of Automotive and Components Companies Registered on the IDX. *Journal of Accounting and Strategic Finance*, 1(01), 45–56. <https://doi.org/10.33005/jasf.v1i01.25>
21. Rahul, K., Seth, N., & Dinesh Kumar, U. (2018). Spotting Earnings Manipulation: Using Machine Learning for Financial Fraud Detection. In M. Bramer & M. Petridis (Ed.), *Artificial Intelligence XXXV* (Vol. 11311, pp. 343–356). Springer International Publishing. https://doi.org/10.1007/978-3-030-04191-5_29
22. Tsai, C.-F., & Chiou, Y.-J. (2009). Earnings management prediction: A pilot study of combining neural networks and decision trees. *Expert Systems with Applications*, 36(3), 7183–7191. <https://doi.org/10.1016/j.eswa.2008.09.025>
23. Veganzones, D., & Séverin, E. (2025). Earnings management visualization and prediction using machine learning methods. *International Journal of Accounting Information Systems*, 56, 100743. <https://doi.org/10.1016/j.accinf.2025.100743>
24. Xinyue, C., Zhaoyu, X., & Yue, Z. (2020). Using Machine Learning to Forecast Future Earnings. *Atlantic Economic Journal*, 48(4), 543–545. <https://doi.org/10.1007/s11293-020-09691-1>