

AUDITUL CONTINUITĂȚII ACTIVITĂȚII: METODE MODERNE DE ANALIZĂ ȘI EVALUARE

GOING CONCERN AUDIT: MODERN METHODS OF ANALYSIS AND EVALUATION

Autor: Alexandrina LUNGU

alexalungu@outlook.com

Universitatea de Stat din Moldova

Cordonator științific: Elena PETREANU

Dr., conf. univ., Universitatea de Stat din Moldova

ORCID: 0000-0001-7024-3081

elena.petreanu@usm.md

Abstract. *This article explores modern methods used in assessing going concern within financial audits, highlighting the shift from traditional, indicator-based evaluations to advanced techniques powered by artificial intelligence and machine learning. Models such as neural networks, LSTM, GRU, and NLP tools enable auditors to detect financial risks early, analyze patterns in large datasets, and predict insolvency with high accuracy. Additionally, stress testing and hybrid models improve forecasting capabilities. While automation enhances audit quality, concerns remain about transparency, data bias, and the need for specialized training. The study emphasizes a balanced approach that combines technological tools with auditor judgment.*

Key words: *going concern, audit, artificial intelligence, machine learning, risk assessment, financial stability.*

JEL cod: M42

Introducere

Evaluarea continuității activității este esențială în auditul financiar, având un rol crucial în prevenirea riscurilor de insolvență. Standardul ISA 570 (revizuit), Continuitatea activității impune auditorilor analiza factorilor care pot afecta stabilitatea unei entități [6, p.4]. Metodele moderne, precum inteligența artificială (IA), analiza Big Data și modelele predictive, permit o identificare mai precisă a riscurilor. Această lucrare oferă o prezentare a metodelor moderne utilizate în evaluarea continuității activității în audit.

Conținut

Evaluarea continuității activității unei companii presupune analiza capacității acesteia de a funcționa fără dificultăți majore timp de cel puțin 12 luni de la data raportării, evitând falimentul sau lichidarea. Auditorii sunt responsabili de verificarea validității ipotezei utilizate de conducere, bazându-se pe probe concrete și pe o analiză detaliată a factorilor de risc, fie că aceștia sunt financiari, operaționali sau externi. Dacă în trecut această evaluare se realiza prin metode tradiționale, bazate pe indicatori financiari și analize statice, astăzi procesul a evoluat considerabil. Integrarea inteligenței artificiale, a tehnologiilor de machine learning și a testelor de stres permite auditorilor să detecteze riscurile mai rapid și să ofere recomandări precise pentru menținerea stabilității financiare [1, p.3].

Progresele tehnologice din domeniul inteligenței artificiale și analiza Big Data au revoluționat modul în care auditorii evaluează continuitatea activității unei firme. Modelele IA sunt capabile să analizeze și să proceseze volume impresionante de date financiare și operaționale într-un timp foarte scurt, identificând tipare și tendințe care ar putea trece neobservate în cazul unei analize tradiționale. Spre exemplu, rețelele neuronale artificiale (Artificial neural networks-ANN) sunt inspirate din funcționarea creierului uman și permit detectarea tiparelor ascunse în datele istorice ale unei

companii. Dacă anumite combinații de indicatori financiari au fost asociate anterior cu probleme de continuitate, ANN-urile vor învăța să recunoască aceste modele și să semnaleze companiile expuse la riscuri similare [9, p.210].

Pe lângă rețelele neuronale, machine learning-ul supravegheat este o altă tehnică avansată utilizată în procesul de audit. Acest model presupune antrenarea unui algoritm pe un set de date etichetate, permițându-i să facă predicții precise pentru noile date. De exemplu, un astfel de model poate învăța să recunoască firmele care au intrat în faliment pe baza unor factori precum scăderea fluxului de numerar, creșterea datoriilor sau pierderile continue. Ulterior, poate analiza datele altor companii pentru a estima probabilitatea ca acestea să se confrunte cu dificultăți similare [5, p.6].

Un alt progres semnificativ în audit este utilizarea procesării limbajului natural (NLP) pentru analiza documentelor financiare, a declarațiilor managementului și a rapoartelor contabile. Această tehnologie permite detectarea unor termeni precum „incertitudine”, „pierderi semnificative” sau „probleme de lichiditate”, care pot indica riscuri financiare. Spre exemplu, un model NLP poate examina sute de rapoarte financiare și poate evidenția frecvența acestor termeni, oferind auditorilor un instrument suplimentar pentru identificarea firmelor aflate în dificultate [8, p.6].

În plus, modelele Long Short-Term Memory (LSTM) și Gated Recurrent Unit (GRU) sunt extrem de eficiente în previzionarea evoluțiilor financiare, deoarece rețin informații din trecut și le folosesc pentru a anticipa viitorul. Spre deosebire de modelele tradiționale, care analizează relațiile dintre variabile într-un moment static, aceste modele pot recunoaște tipare financiare pe termen lung. Dacă o companie prezintă scăderi constante ale fluxului de numerar și o creștere a gradului de îndatorare, modelele LSTM și GRU pot estima probabilitatea ca aceasta să nu-și mai poată continua activitatea. Studiile realizate de Chi & Chu (2021) au demonstrat că aceste modele pot anticipa falimentele cu o acuratețe de peste 94%, ceea ce le face instrumente extrem de valoroase în domeniul auditului [3, p.12].

Modelele predictive de tip machine learning joacă un rol important în previzionarea riscurilor, permițând clasificarea firmelor în funcție de probabilitatea de faliment. Modelul Z-Score al lui Altman (1968) este unul dintre cele mai utilizate, bazându-se pe cinci indicatori financiari esențiali – rentabilitatea activelor, lichiditatea, gradul de îndatorare, capitalizarea pieței și vânzările raportate la active [2, p.591]. Acest model este aplicat în special companiilor producătoare, însă a fost adaptat ulterior și pentru alte sectoare economice.

În paralel, modele mai avansate precum Support Vector Machines (SVM) și Random Forest permit o clasificare mai precisă a companiilor pe baza riscului de necontinuitate. SVM este un algoritm puternic care creează un „plan optim de separare” între firmele stabile și cele cu risc ridicat, fiind eficient chiar și atunci când datele disponibile sunt limitate. În schimb, Random Forest utilizează un ansamblu de arbori de decizie pentru a realiza o clasificare robustă. Fiecare arbore analizează aspecte diferite ale datelor financiare, iar rezultatul final este determinat printr-un mecanism de „vot majoritar”, ceea ce asigură o analiză echilibrată și reduce riscul de eroare [4, p.2][3, p.4].

Modelele hibride, precum CART-RNN (Classification and Regression Tree combinat cu Recurrent Neural Networks), combină avantajele analizei clasice cu capacitatea de învățare a rețelelor neuronale. CART clasifică firmele în funcție de riscul actual, iar RNN analizează datele istorice pentru a prezice viitoarele probleme financiare. Studiile recente, precum cel realizat de Jan (2021), arată că aceste modele pot ajunge la o precizie de până la 95% în identificarea firmelor cu risc ridicat [7, p.17].

Deși modelele de inteligență artificială au numeroase avantaje, metodele econometrice clasice rămân relevante. Regresiile logistice și modelele precum cel al lui Ohlson (1980) sunt utilizate pentru estimarea probabilității de faliment, corelând factori precum lichiditatea, rentabilitatea și gradul de îndatorare. Aceste metode sunt apreciate pentru interpretabilitatea lor ridicată, însă au limitări în

comparație cu modelele bazate pe inteligență artificială, deoarece presupun relații liniare între variabile și nu pot surprinde efecte complexe[10, p.110].

Deși integrarea inteligenței artificiale în audit oferă multiple beneficii, auditorii manifestă rezerve legate de lipsa de transparență a algoritmilor, percepuți adesea ca „cutii negre”. Utilizarea unor seturi de date părtinitoare poate conduce la erori sau discriminare. Astfel, se impune aplicarea unor controale riguroase și testarea soluțiilor IA în medii controlate, pentru a garanta acuratețea și etica rezultatelor. Deși IA promite eficiență sporită, implementarea sa necesită o abordare prudentă și responsabilă.

Concluzie

Tehnologiile moderne au revoluționat auditul continuității activității, oferind instrumente avansate de analiză predictivă. Totuși, succesul acestor metode depinde de echilibrul între inovație și rigoarea profesională. Validarea rezultatelor IA prin metode clasice și formarea continuă a auditorilor sunt esențiale pentru asigurarea unui audit de calitate, etic și fiabil.

Referințe bibliografice

1. Abdelwahed, A.S., Abu-Musa, A.A., Badawy, H.A. et al. Unleashing the beast: the impact of big data and data analytics on the auditing profession—Evidence from a developing country. *Future Business Journal*, 11, 12 (2025). Disponibil la: <https://doi.org/10.1186/s43093-024-00420-7>
2. Altman, E. I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609 (1968). Disponibil la: <https://www.jstor.org/stable/2978933>
3. Chi, Der-Jang & Chu, Chien-Chou. Artificial Intelligence in Corporate Sustainability: Using LSTM and GRU for Going Concern Prediction. *Sustainability*, 13, 11631 (2021). Disponibil la: <https://doi.org/10.3390/su132111631>
4. Chi, Der-Jang & Shen, Zong-De. Using Hybrid Artificial Intelligence and Machine Learning Technologies for Sustainability in Going-Concern Prediction. *Sustainability*, 14, 1810 (2022). Disponibil la: <https://doi.org/10.3390/su14031810>
5. El Gawad, Samar Fathy Abd. The Effect of Using Machine Learning Algorithms Alternatives on the Prediction Accuracy of Going Concern Opinion Prepared. *Middle East Journal of Accounting and Finance*, (2023). Disponibil la: https://masf.journals.ekb.eg/article_325469_5bacb31f00e12e2cdc1d9c32fb12b091.pdf
6. International Auditing and Assurance Standards Board (IAASB). ISA 570 (Revised) – Going Concern (2016). Disponibil la: [https://www.ifac.org/_flysystem/azure-private/publications/files/ISA-570-\(Revised\).pdf](https://www.ifac.org/_flysystem/azure-private/publications/files/ISA-570-(Revised).pdf)
7. Jan, C.L. Using deep learning algorithms for CPAs' going concern prediction. *Information*, 12, 73 (2021). Disponibil la: <https://www.mdpi.com/2078-2489/12/2/73>
8. Kokina, Julia; Blanchette, Shay; Davenport, Thomas H.; Pachamanova, Dessislava. Challenges and opportunities for artificial intelligence in auditing: Evidence from the field. *International Journal of Accounting Information Systems*, Volume 56, 100734 (2025). Disponibil la: <https://www.sciencedirect.com/science/article/pii/S1467089525000107>
9. Lenard, Mary; Alam, Pervaiz; Madey, Gregory. The Application of Neural Networks and a Qualitative Response Model to the Auditor's Going Concern Uncertainty Decision. *Decision Sciences*, 26, 209–227 (2007). <https://doi.org/10.1111/j.1540-5915.1995.tb01426.x>. Disponibil la: <https://doi.org/10.1111/j.1540-5915.1995.tb01426.x>
10. Ohlson, J. A. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109–131 (1980). Disponibil la: <https://www.jstor.org/stable/2490395>
11. The Institute of Chartered Accountants in England and Wales (ICAEW). Coronavirus: Introducing reverse stress testing (2020). Disponibil la: <https://www.icaew.com/technical/audit-and-assurance/professional-scepticism/stress-testing>