DOI: https://doi.org/10.53486/sstc2026.v3.60
CZU: 658.155:347.736

FINANCIAL INDICATORS AS TOOLS FOR PREDICTING BANKRUPTCY

INDICATORI FINANCIARI CA INSTRUMENTE DE ANTICIPARE A FALIMENTULUI

URSACHI (LUCA) Larisa, masterand, specialitatea: Audit și Guvernanță Corporativă
Universitatea Ștefan cel Mare din Suceava, România, Strada Universității, nr. 13
e-mail: larisa.luca1@student.usv.ro

Abstract:*Financial ratios are widely used to assess the financial condition of firms and to identify early signs of financial distress. This study examines their role in predicting bankruptcy, focusing on key indicators of liquidity, solvency, and profitability. The analysis highlights the relevance of established models, such as the Altman Z-score and the Ohlson model, in evaluating insolvency risk. It also discusses the predictive value of financial ratios when analyzed over time, as well as their main limitations related to the use of historical data. The findings indicate that financial ratios remain important tools in bankruptcy prediction, particularly when combined with broader analytical approaches.*
Keywords: *financial ratios, bankruptcy prediction, financial distress, Altman Z-score*
JEL CLASSIFICATION: G33, M41, C53, G32

INTRODUCERE

Falimentul reprezintă, din perspectivă economică și juridică, incapacitatea unei întreprinderi de a-și onora obligațiile financiare asumate, ceea ce conduce, în majoritatea cazurilor, la lichidarea sau reorganizarea acesteia (Abdelkader & Wahba, 2024). Dincolo de consecințele directe asupra entității afectate, falimentul generează efecte negative în lanț asupra angajaților, creditorilor, furnizorilor și asupra climatului economic general. De aceea, capacitatea de a anticipa din timp apariția dificultăților financiare a devenit o preocupare centrală atât pentru mediul academic, cât și pentru practicieni. Indicatorii financiari – calculați pe baza situațiilor financiare ale firmelor – reprezintă instrumente tradiționale prin care se încearcă identificarea semnalelor timpurii ale declinului economic. Aceștia sintetizează relații esențiale între active, pasive, venituri și cheltuieli, oferind o imagine asupra lichidității, solvabilității și profitabilității (Tomczak et al., 2025).

Deși primele modele de predicție a falimentului, precum cel propus de Altman (1968) sau, mai târziu, modelul Ohlson (1980), au fost dezvoltate pe baza unor metode statistice clasice (analiza discriminantă și regresia logistică), cercetările recente pun sub semnul întrebării relevanța acestor instrumente în contextul economic actual, marcat de volatilitate, digitalizare și globalizare. Astfel, pe de o parte, studiile sistematice arată că metodele statistice rămân predominante în practică, dar sunt depășite ca acuratețe de tehnicile de învățare automată (Tomczak et al., 2025). Pe de altă parte, se conturează tot mai clar necesitatea calibrării modelelor predictive la specificul economiilor locale, în special în cazul piețelor emergente (Oyasor, 2025).

În acest context, scopul cercetării este de a analiza critic capacitatea indicatorilor financiari de a anticipa falimentul întreprinderilor, evaluând atât limitele modelelor tradiționale, cât și potențialul modelelor bazate pe învățare automată, cu accent pe aplicabilitatea lor în economiile emergente, inclusiv România și Republica Moldova.

Obiectivele specifice ale studiului sunt:

O1: Identificarea și analiza principalelor categorii de indicatori financiari (lichiditate, solvabilitate, profitabilitate) și a modelelor tradiționale de predicție (Altman Z-score, Ohlson O-score), din perspectiva performanței și limitelor acestora;

O2: Evaluarea comparativă a contribuției aduse de modelele bazate pe învățare automată (Random Forest, XGBoost) în creșterea acurateții predicției falimentului, raportat la metodele statistice clasice;

O3: Investigarea gradului de aplicabilitate a modelelor de predicție în contextul economiilor emergente (România, Republica Moldova) și formularea de recomandări pentru practicieni privind selecția optimă a instrumentelor predictive.

CONȚINUTUL DE BAZĂ

Analiză succintă a surselor bibliografice în domeniul problemei cercetate

Literatura de specialitate privind predicția falimentului prin intermediul indicatorilor financiari este bogată și diversificată, reflectând atât evoluția metodologiilor statistice, cât și adaptarea acestora la specificul diferitelor economii. În vederea atingerii obiectivelor propuse, prezenta secțiune sintetizează contribuțiile relevante din ultimii ani, grupate pe trei direcții majore: (1) modele tradiționale și indicatori financiari de bază; (2) modele avansate bazate pe învățare automată; (3) studii empirice aplicate în economii emergente, cu accent pe România și Republica Moldova.

De la contribuțiile seminale ale lui Beaver (1966) și Altman (1968), analiza discriminantă și regresia logistică au reprezentat pilonii centrali ai predicției falimentului. O validare recentă a acestor instrumente în contextul românesc este oferită de Spulbar et al. (2025), care aplică modelul Altman Z-score unui eșantion de companii listate la Bursa de Valori București. Studiul confirmă relevanța scorului Z ca instrument de avertizare timpurie, evidențiind corelații semnificative între acesta și indicatori precum cheltuielile de exploatare, venitul operațional și valoarea contabilă pe acțiune. De asemenea, Catîru (Gae) (2025) utilizează analiza discriminantă pe un eșantion de 22 de întreprinderi românești, demonstrând că o combinație între rata fondului de rulment, rata de autofinanțare a activelor totale, rentabilitatea activelor și capacitatea de îndatorare permite o clasificare corectă a firmelor sănătoase versus cele aflate în dificultate.

Pe plan internațional, o contribuție de sinteză esențială aparține lui Tomczak et al. (2025), care realizează o analiză sistematică a peste 180 de lucrări științifice și a peste 400 de modele de predicție. Concluzia principală a acestui studiu este că, deși metodele statistice (regresia logistică, analiza discriminantă) rămân predominante în practică, acuratețea lor este semnificativ inferioară celei oferite de modelele de învățare automată. Cei mai frecvent utilizați indicatori financiari identificați de Tomczak et al. (2025) sunt: rata datoriei totale, rata capitalurilor proprii, lichiditatea curentă, lichiditatea rapidă, rentabilitatea activelor (ROA) și rentabilitatea capitalurilor proprii (ROE). Acești indicatori reflectă, așadar, trei dimensiuni fundamentale ale sănătății financiare – gradul de îndatorare, lichiditatea și profitabilitatea – care vor fi analizate în continuare.

Limitele modelelor statistice clasice, în special dependența de ipoteza de normalitate și liniaritate, au determinat cercetătorii să exploreze tehnici alternative de învățare automată. Sidarta (2025) realizează o analiză comparativă a mai multor astfel de modele, arătând că Random Forest atinge o acuratețe de până la 96,7%, fiind ușor superior lui XGBoost (aproximativ 96%), în timp ce rețelele neuronale artificiale și mașinile cu vectori suport (SVM) înregistrează performanțe ușor mai reduse. Studiul confirmă, de asemenea, că indicatorii de profitabilitate și gradul de îndatorare sunt predictorii cei mai influenți, indiferent de modelul ales.

O direcție și mai recentă de cercetare explorează aplicabilitatea modelelor de tip fundație (foundation models) în predicția falimentului. Kostrzewa et al. (2025) compară performanțele unor modele precum Llama cu metodele clasice de învățare automată (XGBoost, CatBoost) și concluzionează că, deocamdată, modelele specializate rămân superioare. Modelele fundație necesită volume mari de date și resurse computaționale semnificative, iar beneficiile lor în acest domeniu specific nu sunt încă dovedite. Cu toate acestea, autorii sugerează că pe măsură ce aceste modele vor evolua, ele ar putea aduce îmbunătățiri în special în ceea ce privește interpretabilitatea predicțiilor.

O problemă centrală a cercetării o reprezintă măsura în care modelele dezvoltate pe piețe dezvoltate (precum cele din SUA sau Europa de Vest) pot fi aplicate cu succes în economiile emergente. Oyasor (2025) oferă o dovadă empirică relevantă din Nigeria, arătând că modelele calibrate local (denumite IN01 și IN05) depășesc semnificativ modelele universale Altman și Ohlson

în ceea ce privește acuratețea predicției. Acest rezultat sugerează că transferul direct al instrumentelor predictive din piețele dezvoltate poate conduce la erori semnificative, iar adaptarea la specificul local – inclusiv la practicile contabile, structura pieței și ciclurile economice regionale – este esențială.

Pentru România, studiile menționate anterior (Spulbar et al., 2025; Catîru (Gae), 2025) confirmă aplicabilitatea modelului Altman, dar nu efectuează o comparație sistematică cu modele alternative locale. În schimb, pentru Republica Moldova, Fusaru și Muntean (2025) aplică atât modelul Altman Z-score, cât și modelul românesc Anghel unui set de date din sectorul agricol. Concluzia este că modelul Anghel oferă rezultate mai consistente decât variantele standard ale scorului Z, probabil datorită unor similarități mai mari între economiile României și Republicii Moldova. În aceeași direcție, Chistruga și Bădicu (2025) analizează utilitatea scorului Z pentru entitățile agricole din Republica Moldova și identifică principalele limite ale aplicării directe a acestui model, în special în ceea ce privește specificul activelor și al finanțării în agricultură.

Descrierea metodelor de cercetare utilizate

Prezentul studiu se bazează pe o revizuire sistematică a literaturii de specialitate publicate în perioada 2020–2026, având ca scop sintetizarea principalelor contribuții în domeniul predicției falimentului prin intermediul indicatorilor financiari. Metodologia adoptată respectă, în linii mari, principiile ghidurilor de raportare a revizuirilor sistematice (PRISMA), adaptate la specificul unei analize descriptive bazate pe surse secundare.

Tabelul 1 Criterii de selectie

Criteriu	**Detaliere**
Tipul publicațiilor	Articole științifice publicate în reviste indexate, lucrări conferințe, preprinturi
Perioada de acoperire	2020 – aprilie 2026
Limba	Engleză, română
Domeniul tematic	Predicția falimentului, indicatori financiari, modele statistice, învățare automată, aplicații în economii emergente

Sursa: Elaborare proprie

Rezultatele obținute

In urma aplicării metodologiei descrise, au fost sintetizate contribuțiile a 14 studii relevante, grupate în funcție de tipul modelului utilizat și de contextul economic analizat. Rezultatele sunt prezentate sintetic în Tabelul nr. 2, iar în continuare sunt evidențiate constatările majore pe fiecare direcție de cercetare.

Tabelul 2. Sinteza principalelor studii analizate în domeniul predicției falimentului

Nr. crt.	**Autor(i), an**	**Metodă**	**Eșantion / Context**	**Concluzii principale**
1	Spulbar et al. (2025)	Altman Z-score (regresie liniară multiplă)	Companii listate la Bursa de Valori București, România	Scorul Z este un instrument valid de avertizare timpurie; corelații semnificative cu cheltuielile de exploatare, venitul operațional și valoarea contabilă pe acțiune
2	Catîru (Gae) (2025)	Analiză discriminantă	22 de firme românești	Combinația a patru indicatori (fond de rulment, autofinanțare active, ROA, îndatorare) permite clasificarea corectă a

				firmelor sănătoase vs. dificile
3	Chistruga & Bădicu (2025)	Z-score (studiu de caz)	Entități agricole, Republica Moldova	Utilizarea Z-score îmbunătățește semnificativ acuratețea previziunilor financiare pentru entitățile agricole
4	Fusaru & Muntean (2025)	Altman Z-score (Z, Z', Z'') vs. modelul Anghel	12 întreprinderi agricole, Republica Moldova	Modelul Anghel (românesc) oferă cele mai consistente rezultate; toate modelele prezintă limite în context agricol
5	Oyasor (2025)	Altman Z-score, Ohlson O-score, IN01, IN05	Set de date comprehensive din Nigeria, piață emergentă	Modelele locale (IN01, IN05) depășesc semnificativ modelele universale; necesitatea contextualizării instrumentelor predictive
6	Saleem et al. (2025)	Altman Z-score, Ohlson O-score, Shumway hazard; MDA, Logit, Probit	144 firme (72 falimentare + 72 sănătoase), Pakistan	Altman prezice corect falimentul în 83,9%–94,6% cazuri, dar are rata ridicată de fals pozitiv (61,1%–91,1%)
7	Abdulrahman & Bala (2025)	Regresie logistică multivariată	Companii nefinanciare SUA (2017–2021)	LTAT (datorii totale/active totale) are 80% putere predictivă în anul anterior falimentului; OANCFLT (flux numerar/datorii totale) – 65%
8	Tomczak et al. (2025)	Analiză sistematică (180+ lucrări, 400+ modele)	Țările Grupului Visegrád (V4), peste 200.000 companii (2006–2021)	Modelele statistice sunt predominante, dar inferioare ca acurateț față de machine learning; cei mai frecvenți indicatori: DR, ER, CR, QR, ROA, ROE
9	Sidarta (2025)	Logistic Regression, Decision Tree, Random Forest, XGBoost	Set de date financiare (dummy dataset, Kaggle)	Random Forest (96,7%) > XGBoost (≈96%) > Logistic Regression (96%) > Decision Tree (95%); profitabilitatea și gradul de îndatorare – predictorii cei mai importanți
10	Cheraghali & Molnár (2025)	Evaluare sistematică a peste 6.100 de modele	IMM-uri din SUA	LightGBM și XGBoost au cea mai bună performanță out-of-sample; nu necesită rebalansare; Logit necesită feature selection și rebalansare

11	Pérez-Núñez (2025)	Revizuire sistematică (PRISMA, PICOC) a modelelor AI	Instituții financiare	XGBoost, LSTM și modelele hibride ating acurateți >99%, dar necesită volume mari de date și resurse computaționale
12	Kostrzewa et al. (2025)	Llama-3.3-70B-Instruct, TabPFN vs. XGBoost/CatBoost	Peste 1 milion de companii din V4	XGBoost și CatBoost depășesc în mod constant modelele fundație; LLM-urile au estimări de probabilitate nesigure
13	Zavitsanos et al. (2025)	Revizuire sistematică a literaturii ML	Analiza situațiilor financiare	Două cazuri de utilizare principale: detecția erorilor și predicția dificultăților financiare; clasificare pe patru dimensiuni metodologice
14	Bui et al. (2025)	Analiză comparativă: modele statistice vs. ML (XGBoost, Random Forest)	Firme listate în Vietnam (2010–2021)	XGBoost și Random Forest depășesc semnificativ logistica tradițională; activele totale, lichiditatea și creșterea capitalurilor proprii – variabile importante

Sursa: prelucrare proprie pe baza literaturii analizate

Analiza comparativă a celor 14 studii sintetizate în Tabelul nr. 2 relevă trei constatări majore, cu implicații directe asupra obiectivelor cercetării. În primul rând, se observă o tensiune clară între acurateţe și aplicabilitate: modelele de învățare automată (Random Forest, XGBoost, LSTM) raportează acurateți care depășesc 96% (Sidarta, 2025; Pérez-Núñez, 2025), iar uneori chiar 99%, însă aceste performanțe sunt obținute fie pe seturi de date simulate (cazul lui Sidarta), fie necesită volume masive de date și resurse computaționale care depășesc capacitățile majorității firmelor din economiile emergente. În schimb, modelele tradiționale precum Altman Z-score, deși mai puțin precise, rămân accesibile și aplicabile imediat, chiar dacă studiul lui Saleem et al. (2025) semnalează o problemă gravă a acestora – rata extrem de ridicată de fals pozitiv (61,1%–91,1%), ceea ce înseamnă că multe firme sănătoase sunt clasificate greșit ca fiind în pericol de faliment.

În al doilea rând, contextul economic local nu este doar un detaliu, ci un factor determinant al performanței predictive. Studiile pe piețe emergente – Nigeria (Oyasor, 2025), Pakistan (Saleem et al., 2025), Vietnam (Bui et al., 2025), Republica Moldova (Fusaru & Muntean, 2025; Chistruga & Bădicu, 2025) – demonstrează în mod convergent că modelele universale, dezvoltate pe baza datelor din SUA sau Europa de Vest, au o acuratețe semnificativ redusă atunci când sunt aplicate direct. Mai mult, chiar și în cadrul aceleiași țări, sectorul agricol din Republica Moldova prezintă specificități care limitează aplicabilitatea scorului Z (Chistruga & Bădicu, 2025). Această constatare validează obiectivul nr. 3 al prezentei cercetări și subliniază necesitatea unor modele calibrate local sau, cel puțin, a unor ajustări ale pragurilor de decizie.

În al treilea rând, există un decalaj metodologic semnificativ între cercetarea de vârf și practica curentă. Pe de o parte, Tomczak et al. (2025) arată că metodele statistice clasice sunt încă predominante în literatură, deși sunt inferioare ca acuratețe. Pe de altă parte, studiile care utilizează modele avansate (Kostrzewa et al., 2025; Cheraghali & Molnár, 2025) evidențiază că nici măcar între metodele de învățare automată nu există un consens: LightGBM și XGBoost par a fi cele mai robuste,

în timp ce modelele fundație (LLM) sunt încă nepractice pentru această sarcină specifică. O limită critică a literaturii actuale, reflectată indirect în tabel, este lipsa unor metrici standardizate de comparare – unele studii raportează acuratețea globală, altele sensibilitatea (rata de identificare corectă a falimentelor), iar altele specificitatea (rata de identificare corectă a firmelor sănătoase). Această eterogenitate metodologică face dificilă o comparație directă și impune prudență în generalizarea concluziilor.

În concluzie, tabelul confirmă faptul că indicatorii financiari rămân instrumente utile, dar nu suficiente. Direcțiile de cercetare viitoare ar trebui să se concentreze pe: (a) dezvoltarea unor modele hibride care să combine simplitatea și interpretabilitatea modelelor tradiționale cu puterea predictivă a algoritmilor de învățare automată; (b) validarea acestor modele pe seturi de date reale din economii emergente, inclusiv România și Republica Moldova; și (c) publicarea unor repere metodologice clare (benchmarking) care să permită compararea obiectivă a performanțelor între studii.

CONCLUZII

Indicatorii financiari rămân un instrument important pentru anticiparea falimentului, oferind perspective asupra lichidității, solvabilității și profitabilității unei firme. Modelele de predicție actuale combină aceste indicatori cu tehnici statistice și algoritmi de învățare automată pentru a spori precizia evaluării riscului. Studii recente confirmă faptul că integrarea abordărilor tradiționale cu metode moderne poate contribui la o estimare mai bună a probabilității de faliment, adaptată la specificul economic al fiecărei regiuni sau industrii.

Pentru practicieni, utilizarea adecvată a indicatorilor financiari nu înseamnă doar calcularea acestora, ci interpretarea lor în contextul unei analize integrate și actualizate, care ține seama de dinamica pieței, de calitatea datelor și de evoluțiile tehnologice în domeniul modelării predictive.

REFERINȚE:

1. Abdelkader, N. A. M., & Wahba, H. H. (2024). A proposed multidimensional model for predicting financial distress: An empirical study on Egyptian listed firms. Future Business Journal **10**, 42 https://doi.org/10.1186/s43093-024-00328-2
2. Abdulrahman& Bala (2025). The Role of Financial Ratios in Bankruptcy Prediction: An Empirical Study Using Contemporary Financial Data. FUDMA Journal of Accounting and Finance Research. Disponibil la adresa: https://www.researchgate.net/publication/392155586_The_Role_of_Financial_Ratios_in_Bankruptcy_Prediction_An_Empirical_Study_Using_Contemporary_Financial_Data
3. Billios, D., Seretidou, D., & Stavropoulos, A. (2024). The Power of Numerical Indicators in Predicting Bankruptcy: A Systematic Review. Journal of Risk and Financial Management, 17(10), 433. Disponibil la adresa: https://www.mdpi.com/1911-8074/17/10/433
4. Bui, T. H., Truong, T. T. D., & Tran, T. P. T. (2025). Financial ratios as indicators in bankruptcy prediction: A comparative analysis of statistical and machine learning models. Preprint. Disponibil la adresa: https://www.researchgate.net/publication/390295866_Financial_ratios_as_indicators_in_bankruptcy_prediction_A_comparative_analysis_of_statistical_and_machine_learning_models
5. Catîru (Gae), D. (2025). Assessment of bankruptcy risk in Romanian enterprises using discriminant analysis. Analele Universității din Craiova, Seria Științe Economice, (44), 28-40. https://www.ceeol.com/search/article-detail?id=1341002
6. Chistruga, M., & Bădicu, G. (2025). Usability of Z-score for predicting bankruptcy risk: a case study for agrarian sector entities in Moldova. Journal of Social Sciences, 8(1), 45-58. https://repository.utm.md/xmlui/handle/5014/29146
7. Fusaru, I., & Muntean, N. (2025). Financial sustainability assessment in Moldovan agriculture through Z-score analysis: insights from Romanian models. Finansy Ukrayiny, 31(5), 45-62. https://finukr.com.ua/index.php/journal/article/view/136
8. Hanun, R. U., & Ferdiani, C. (2025). Literature Analysis on Financial Distress and Bankruptcy Prediction. GeneratedP. https://generatedp.com/index.php/fr/article/view/47/49
9. Kostrzewa, M., et al. (2025). Are foundation models useful for bankruptcy prediction? arXiv preprint, arXiv:2511.16375. https://doi.org/10.48550/arXiv.2511.16375
10. Oyasor, E. I. (2025). Bankruptcy prediction and financial risk assessment in emerging markets: Evidence from Nigeria. Gusau Journal of Accounting and Finance, 6(1), 255-269. https://doi.org/10.57233/gujaf.v6i1.18
11. Saleem, U., Noreen, U., Shafique, A., & Danila, N. (2025). Downside risk applied to bankruptcy predicting models. Cogent Economics & Finance, 13(1), 2560023.

12. Sidarta, A. L. (2025). Comparative analysis of machine learning models in predicting corporate bankruptcy. Jurnal Akuntansi Indonesia, 11(2), 125-140. https://doi.org/10.29080/jai.v11i02.2269
13. Spulbar, C., Cinciulescu, D., Ene, C. C., & Spulbar, L. F. (2025). Altman Z-score modeling and financial risk analysis: An empirical study on companies listed on the Bucharest Stock Exchange. Studies in Business and Economics, 20(3), 314-340. https://doi.org/10.2478/sbe-2025-0037
14. Tomczak, S. K., Karas, M., Kristóf, T., Duricova, L., & Durica, M. (2025). Identification of key indicators, model development, and validation methods for bankruptcy prediction: A systematic review for the Visegrad Group. Forum Scientiae Oeconomia, 13(3), 156-197. https://doi.org/10.23762/FSO_VOL13_NO3_7

Coordonator științific: GROSU Veronica, prof. univ., dr.
Universitatea „Ștefan cel Mare" din Suceava, România,
Suceava, Strada Universității, nr. 13
e-mail: veronica.grosu@usv.ro