

## EVALUAREA RISCULUI DE CREDIT: O ANALIZĂ A DIVERSELOR METODE DE EVALUARE A RISCULUI DE CREDIT

*Alexandru BRĂILĂ, Mariana MORARU*

*Catedra Modelare Matematică și Informatică Economică*

This study explores financial credit risk assessment. This is an important issue because there is currently no standardized method used by financial institutions for the assessment of credit risk. A critical evaluation of the most popular credit risk assessment methods – the judgemental method and credit-scoring – highlights a number of limitations when used on their own. Some financial institutions may choose to implement neural the method with least disadvantages, accepting the risk that the assumptions may not correspond to reality, but opting for better performance of the model. Under these circumstances, the implementation of some measures of performance seems imperative.

Managementul riscului este un domeniu ce a devenit extrem de important în societatea economică de astăzi. Afacerile concurează agresiv pentru ocuparea unei cote de participare mai mari pe piață și, corespunzător, își asumă mai multe riscuri. De aceea, implementarea managementului riscului în instituțiile financiare este crucială. Managementul riscului încearcă să dezințineze, să reducă și să administreze riscurile și să intensifice beneficiile, să evite prejudiciile de la asumarea acestor riscuri [1]. În sectorul financiar, managementul riscului este un domeniu de interes deosebit datorită crizelor financiare ale ultimelor două decenii [2]. Conform Basle Committee, organismul internațional de supraveghere bancară, cea mai vastă sursă a severelor probleme bancare este riscul de credit. Scandalurile și crizele financiare severe, precum default-ul din Rusia și criza tehilei, sunt legate de riscul de credit. Un alt indicator de importanță crucială a riscului de credit este faptul că în ultimii ani s-a observat o creștere constantă a default-urilor și falimentelor și o reducere în credibilitatea instituțiilor counterparty ale instituțiilor financiare [3,4]. Aceste premise au asigurat inițiativa explorării domeniului riscului de credit.

Managementul riscului de credit conține 4 etape: identificarea, măsurarea, managementul și controlul riscului de credit. Cea mai mare provocare dintre aceste etape o constituie măsurarea riscului de credit. În ultimii ani, s-a avansat considerabil în dezvoltarea modelelor de evaluare a riscului de credit, dar până acum nimeni nu a analizat diverse modele în termenii eficienței lor relative. Examinarea critică a diverselor metode de evaluare a riscului de credit utilizate de instituțiile financiare evidențiază diversele lor avantaje și dezavantaje, în funcție de reviuul literaturii, și asigură o arhitectură pentru evaluarea riscului de credit.

Evaluarea riscului de credit reprezintă încă un domeniu în plină dezvoltare și nu există metodologii standarde urmate de instituțiile financiare. Fiecare din metodologii prezintă unele avantaje și deficiențe, și aceeași metodă poate fi eficientă într-o situație, dar prejudiciabilă în alta. Aplicarea oricărei metode poate fi periculoasă dacă utilizatorul crede în perfecțiunea acesteia și o acceptă fără gândire critică, dar poate fi valoroasă dacă utilizatorul este conștient de contextul, avantajele și dezavantajele ei. Luând în considerare aceste aspecte, prezenta analiză pune în discuție metoda aprecierii (metoda calitativă) și credit scoring-ul.

*Metoda aprecierii, sau metoda calitativă,* reprezintă metoda tradițională utilizată pentru evaluarea riscului de credit. În conformitate cu aceasta, pentru evaluarea riscului de credit trebuie luați în considerare factorii specifici legați de contraparte și mediul extern. Analistul riscului de credit culege informația despre aceste elemente și formează o listă cu caracteristicile acestora. Astfel, analistul poate evalua expunerea riscului de credit al acestui caz, după ce aceste caracteristici au fost meticolos examinate [6].

Factorii examinați, specifici contrapărții, includ totul ce poate amenința angajamentul său față de instituția financiară. Cei mai importanți dintre aceștia sunt: caracterul contrapărții, capacitatea și garanțiile sale. Termenul de caracter este definit ca „consimțirea de a rambursa” [7]. Deseori, identificarea contrapărții necinstite este dificilă, dar istoria financiară și referințele personale sunt indicatori temeinici [5,7]. În plus, un interviu se poate dovedi a fi egal de important. Răspunsurile documentate la întrebări, cum este scopul împrumutului, trebuie să fie convingătoare [6].

Metoda aprecierii de asemenea examinează unele elemente legate de capacitatea contrapărții. Declarațiile despre profitabilitate, lichiditate, cash flow-uri, structura capitalului și proiectele financiare sunt esențiale

pentru determinarea capacității inițiale și continue a debitorului de rambursare. O companie fără profitabilitate [8] și lichiditate [9] poate supraviețui o perioadă scurtă de timp. În plus, poate fi prejudiciant pentru o instituție financiară să asigure un credit unei companii supradependente de credit [8] sau unei companii cu cashflow-uri negative [9]. Rapoartele financiare asigură informația vitală despre aceste elemente. Evoluția stock-market-ului este un alt indicator al capacității contrapărții. Fluctuațiile în performanța cotelor-părți sunt de obicei considerate ca semnale de pericol. Mai mult ca atât, punctele forte și slabe (primele două etape ale analizei SWOT) ale companiei în resurse și management sunt examinate în conformitate cu metoda aprecierii [9]. Un alt factor specific contrapărții se relaționează cu garanțiile asigurate. Factorii mediului extern afectează sensibilitatea contrapărții la forțele externe, evenimentele în afara controlului personal al clientului, precum sunt riscurile unei crize politice, recesiunile economice ale unui război sau riscurile industriale.

După examinarea caracteristicilor de mai sus, are loc evaluarea. La prima vedere, metoda aprecierii pare rațională și eficientă. Simplitatea metodei poate fi apreciată ca un avantaj important. Fără matematici complicate sau pachete de programe, numai cu o colecție de informație și contact personal, metoda aprecierii este o modalitate excelentă de utilizare eficientă a abilităților naturale ale analiștilor. Mai mult ca atât, este o metodă ce dezvoltă o relație apropiată între instituțiile financiare și contrapărți. Deficiența metodei aprecierii este că eșuează în asigurarea informației suficiente despre caracteristicile generale și performanța portofoliului de credit. Aceasta privează analiștii riscului de credit de oportunitatea analizei unui risc marginal și a unei rambursări marginale în adăugarea unei noi tranzacții la un portofoliu de credit existent.

*Credit scoring* este o procedură de modelare ce permite previziunea comportamentului viitor în baza evaluării performanței anterioare. Prima etapă a credit scoring-ului este identificarea variabilelor explicative (exogene) derivate din formularele de solicitare a creditului, rapoarte sau alte surse de informație pe care contrapărțile le pun la dispoziția instituțiilor financiare. Această informație poate conține un amestec de variabile continue (precum e venitul) și variabile de categorie (precum e deținătorul unei proprietăți) [10]. Gruparea în intervale tipice transformă variabilele continue în variabile de categorie [10]. Cea de-a doua etapă este asigurarea unui punctaj rezultat din metodele statistice. Având în aplicare baze de date mari despre rapoartele de credit anterioare, instituțiile financiare încearcă să identifice anumiți factori-cheie ce determină valorificarea expunerii creditului. Variabilele explicative, care de obicei sunt numite caracteristici, formează fluxul de intrare al modelului. Valorile pe care acestea le pot lua sunt numite atribute. Output-ul reprezintă un punctaj ce măsoară valorificarea fiecărei contrapărți [11].

Cele mai cunoscute tehnici ce pot fi utilizate pentru credit scoring sunt analiza discriminantă, modelul logit și rețelele neurale. Analiza discriminantă derivează o combinație liniară a câtorva variabile independente (de obicei, indicatori financiari) ce distinge între două grupuri anterior definite de contrapărți: de încredere (reliable) și de neîncredere (non-reliable). Analiza logit utilizează probabilitatea cumulativă logistică, în timp ce rețelele neurale includ un model al inteligenței artificiale. Majoritatea analiștilor aplică una din aceste tehnici sau o combinație a lor.

**Analiza discriminantă** încearcă să deriveze o combinație liniară a câtorva variabile independente pentru a distinge între două grupuri anterior definite de contrapărți: de încredere și de neîncredere. Prima etapă este selectarea variabilelor independente ale ecuației. De obicei, variabilele independente sunt selectate cu ajutorul cunoștințelor experților și al experienței. Dar, principala caracteristică a acestei metode este subiectivitatea [11].

Analiza discriminantă derivează combinațiile liniare din ecuația cu următoarea formă:

$$S = b_0 + \sum_{i=1}^m b_i x_i, \text{ unde } i = 0, 1, 2, \dots, m,$$

unde:  $S$  este scorul sau punctajul discriminant,  $b_i$  – coeficienții estimați,  $x_i$  – variabilele independente explicative. Odată punctată, expunerea la credit este atribuită unui grup de contrapărți de încredere și neîncredere. Aceasta este atinsă prin determinarea unui scor sau punctaj cutoff ce maximizează varianța dintre grupuri, în timp ce minimizează varianța în fiecare grup. Relația este exprimată ca un raport al varianței între grupuri și în grupuri. Companiile ce se află sub cutoff sunt așteptate să falimenteze.

Cele mai comune forme ale modelului discriminant în credit scoring sunt modelul Z-scor și ZETA, propuse de Altman în 1968, și sunt construite pe 5 indicatori financiari, ce i-au forma caracteristicilor.

Însă, unele critici ale metodei de analiză discriminantă țin de cerințele statistice restrictive impuse modelului, devenind problematice atunci când sunt utilizate variabilele independente dummy, în special în cazul companiilor falimentare [8].

**Regresia logistică** este o altă metodă des utilizată în credit scoring. Asemenea analizei discriminante, această tehnică apreciază variabilele independente și atribuie un punctaj  $Z$ . Acesta ia forma unei probabilități de eșec. Punctajul  $Z$  reprezintă probabilitatea eșecului fiecărei contrapărți într-un eșantion. Prin urmare, această abordare nu necesită ca variabilele explicative să urmeze o distribuție normală. Modelul are următoarea formă:

$$\ln(P_x / Q_x) = b_0 + \sum_{i=1}^m b_i x_i, \text{ unde } i = 0, 1, 2, \dots, m,$$

unde:  $P_x$  se referă la probabilitatea falimentului,  $Q_x$  – probabilitatea că contrapartea nu va eșua,  $b_i$  – coeficienții estimați și  $x_i$  – caracteristicile. Iar ecuația pentru scorul final, numită și funcție logistică, este:

$$p = \frac{e^z}{1 + e^z}$$

Însă, regresia logistică nu ia în considerare corelarea dintre variabilele independente și utilizează în principal relațiile liniare între variabilele dependente și independente.

O altă tehnică utilizată pentru credit scoring este metoda **rețelelor neuronale**, care s-a dezvoltat pe baza principiului funcționării creierului [12]. Asemeni creierului, o rețea neuronală implică un număr de unități similare ce constau dintr-o mulțime de elemente de procesare interconectate, care sunt numite neuroni. Procedura urmată în această metodă conține 3 straturi: stratul de intrare, ascuns și de ieșire. Fiecare neuron din aceste straturi are propria funcție de activare sau transfer spre stratul de ieșire. Straturile de intrare și ascuns transmit semnale spre stratul de ieșire [10,12]. Stratul ascuns este extrem de conectat cu experiența, deoarece este ajustat intern prin procedura de instruire a rețelei ce constă în generarea unei reguli de instruire cu algoritmi ai inteligenței artificiale, care permit studierea prin experiență. Rezultatul este o rețea instruită care poate fi utilizată pentru evaluarea noilor cazuri. Este evident că procesele de instruire generate de interacțiunea rețelei cu mediul extern poate modifica legăturile dintre neuroni [13]. Rezultatul  $Y$  al rețelei neuronale cu un singur strat ascuns este indicat de modelul:

$$Y = R \left( \sum_{j=1}^n v_j Q \left( \sum_{i=1}^m w_{ij} x_i \right) \right),$$

unde:  $R$  și  $Q$  sunt funcțiile de activare,  $x_i$  – unitățile  $i$  de procesare la intrare din stratul de intrare,  $v_j$  – ponderile asociate cu unitatea  $j$  de procesare din stratul ascuns și  $w_{ij}$  – ponderile asociate cu unitatea  $i$  de procesare din stratul ascuns [13].

Câteva studii comparative conduse cu privire la performanța acestor modele de scoring au prezentat concluzii controversate. Martin (1977) a identificat niveluri de precizie similare între acuratețea clasificării pentru o regresie logit și o analiză discriminantă în analiza pericolului financiar al unui număr mare de bănci a rezervelor federale între anii 1970-1976. Alte studii comparative au inclus rețelele neuronale; prin urmare, rezultatele lor sunt mai interesante. Un studiu de Altman și alții (1994) a demonstrat că atât analiza discriminantă, regresia logit, cât și rețelele neuronale au obținut aproximativ același grad de precizie.

Prezenta analiză denotă că deși analiza discriminantă și regresia logistică implică mai multe dezavantaje decât rețelele neuronale, aceasta din urmă nu întotdeauna depășește în performanță celelalte metode. Este doar o metodă cu mai puține limitări și constrângeri. Dacă prezumțiile regresiei logistice sau ale analizei discriminante nu sunt violate, atunci aceste metode pot oferi rezultate mai bune. De aceea, selectarea unei metode de către instituțiile financiare pare a fi subiectivă. Unele instituții financiare pot alege să implementeze rețelele neuronale, dat fiind că acestea au cele mai puține dezavantaje. Altele pot alege să implementeze una din celelalte metode, acceptând riscul că prezumțiile pot să nu corespundă realității, dar optând pentru o performanță mai bună a modelului. În aceste circumstanțe, implementarea unor măsuri de performanță este imperativă.

**Referințe:**

1. Waring A., Glendon I. Managing Risk.-International Thomson Business Press,1998.
2. Galindo J., Tamayo P. Credit risk assessment using statistical and machine learning methods as an ingredient for financial intermediaries risk modelling // Comput. Econ. - 2000. - Vol.15. - P.107-143.
3. Brady B. Ratings performance 2001. - New York: Standard & Poor's, 2002.
4. Tillman V. Ratings performance 1999. - New York: Standard & Poor's, 2000.
5. Kalapodas E., Thompson M.E. Credit risk assessment: a challenge for financial institutions // IMA Journal of Management Mathematics. - 2006. - Vol.17. - P.25-26.
6. Koch T.W., McDonald S.S. Bank Management. - Harcourt College Publishers, 2000.
7. Hempel G.H., Simonson D.G., Coleman A.B. Bank Management: Text and Cases. - New York: John Wiley and Sons, 1994.
8. Bass R.M.V. Credit Management. - UK: Stanley Thornes (Publishers) Ltd, 1991.
9. Rice T., Coyle B. Credit risk management: Corporate credit analysis. - UK: Financial World Publishing, 1999.
10. Hand D.J. Modelling consumer credit risk // Journal of Management Mathematics. - 2001. - Vol.12. - P.139-155.
11. Hand D.J., Henley W.E. Statistical clasification methods in consumer credit scoring // J. R. Stat. Assoc., Ser. A. - 1997. - Vol.160. - P.523-541.
12. Summers B., Riding A. Networks that learn and credit evaluation. - Arkansas, USA: University of Central Arkansas, 1996.
13. Hubal O., Meisser S. The swiss credit market. - Switzerland: University of Laussane, 2000.

*Prezentat la 12.02.2007*