
Credit Scoring – abordare generală în contextul IFRS 9

Drd. Luminița-Georgiana ACHIM,
e-mail: luminita.achim28@gmail.com

Drd. Elena MITOI,
e-mail: elena.Mitoi@gmail.com

Drd. Marian Valentin MOLDOVEANU,
e-mail: moldoveanu.valentin3@gmail.com

Drd. Codruț-Ioan ȚURLEA,
e-mail: turleacodrut@gmail.com

Facultatea de Contabilitate și Informatică de
Gestiune, Academia de Studii Economice, România

Rezumat

Odată cu intrarea în vigoare a standardului IFRS 9 – Instrumente financiare, în ianuarie 2018, instituțiile financiare au trecut de la un model de pierderi suportate către un model de perspectivă pentru calculul pierderilor din depreciere. Ca atare, modelele IFRS 9 utilizează în timp estimări ale probabilității de neîndeplinire a obligațiilor și pierderea dată implicit și oferă o reprezentare mai fidelă a riscului de credit, la un moment dat, deoarece acestea se bazează pe experiențele anterioare, precum și pe cele mai recente și prognozate condiții economice. Cu toate acestea, având în vedere fluctuațiile pe termen scurt în condiții macroeconomice, rezultatul final al modelelor de pierderi de credit preconizate este extrem de volatil din cauza sensibilității lor la ciclul de afaceri. În ceea ce privește estimarea probabilității implicite în conformitate cu IFRS 9, metodele cele mai frecvente sunt: Lanțurile Markov, Analiza Supraviețuirii și modelele cu un singur factor (Vasicek și Z-Shift). Dezvoltarea cardurilor de scor este în continuare aceeași ca în cazul modelelor de probabilitate implicită bazată pe evaluări interne, încurajând instituțiile să utilizeze sistemele de rating de credit deja disponibile și să efectueze ajustarea calibrării. Această cercetare prezintă o listă ne-exhaustivă de teste de validare cantitativă care să satisfacă cerințele standardului IFRS 9.

Cuvinte cheie: IFRS 9; credit scoring; teste statistice; instituții financiare;

Clasificare JEL: M41, M21

Vă rugăm să citați acest articol astfel:

Achim, L.-G., Mitoi, E., Moldoveanu, M.V., Țurlea, C.-I., (2021), Credit Scoring – General Approach in the IFRS 9 Context, *Audit Financiar*, vol. XIX, no. 2(162)/2021, pp. 384-396, DOI: 10.20869/AUDITF/2021/162/014

Link permanent pentru acest document:

<http://dx.doi.org/10.20869/AUDITF/2021/162/014>

Data primirii articolului: 22.02.2021

Data revizuirii: 1.03.2021

Data acceptării: 28.03.2021

1. Introducere

Înainte de introducerea standardului IFRS 9 – *Instrumente financiare*, doar instituțiile complexe erau familiare cu sistemele de rating, deoarece acestea erau utilizate pentru modelele de capital intern bazate pe evaluări (IRB) sau de capital economic. Prin urmare, înainte de introducerea IFRS 9 multe instituții mici și mijlocii au implementat metode de rating simpliste. Existența unui sistem de rating adecvat a fost discutată de Hamerle și colaboratorii (2003) care consideră că, de exemplu, un sistem de rating compus din două grade ar fi considerat inadecvat pentru calcularea cerințelor de capital. Deci, în ciuda faptului că IFRS 9 nu prescrie numărul de note care se așteaptă să fie incluse într-un sistem de rating, este încurajat să utilizeze o abordare similară cu cea de la Basel III, în timp ce orientările Băncii pentru Decontări Internaționale (BIS) consideră adecvat un minim de șapte note performante (pentru expunerile cu amănuntul și non-retail) și cel puțin o notă implicită. Mai exact, *credit scoring* se referă la setul de tehnici utilizate de instituții în vederea evaluării bonității unui debitor prin utilizarea modelelor predictive, pentru a facilita procesul de evaluare a creditului, debitorul este acceptat pe baza apetitului de risc al instituției, precum și a valorii maxime care ar putea fi împrumutată.

Modelele *credit scoring* sunt utilizate pentru a prezice probabilitatea de neplată a debitorilor. Pentru a măsura calitatea *credit scoring*, testele cantitative ce pot fi utilizate sunt Indicele Gini, AUROC, Somers' D, statistici KS, statistici informaționale (valoarea informației, greutatea probelor), Testul binomial, Testul Chi-pătrat, Indicele de stabilitate a populației, Indicele Herfindahl-Hirschman (HHI). Astfel de tehnici pot fi utilizate pe tot parcursul procesului de selecție, precum și în scopuri de validare și monitorizare, pentru a evalua calitatea modului după implementarea acestuia.

Studiul va prezenta o listă neexhaustivă a testelor statistice utilizate în validarea *credit scoring*, ce include atât o scurtă descriere, cât și avantaje și dezavantaje. Instituțiile pot aplica o mare varietate de metode atunci când își validează modelele de rating, totuși este esențial să se aplice cel puțin o metodă pentru fiecare discriminare, calibrare, stabilitate și concentrare a nivelului de validare.

2. Stadiul actual al cunoașterii

Credit scoring este considerată o metodă esențială între cele de bănci, în urma expansiunii rapide a industriei creditului la nivel mondial. Este foarte folosit de instituțiile financiare pentru a oferi credite solicitanților buni și pentru a diferenția creditul bun de creditul rău. Decizia care implică

acordarea sau refuzul de a acorda credit unui client poate fi, de asemenea, susținută de tehnici judiciare, care, potrivit lui Sarlija și colab. (2004), se bazează pe cunoștințele și experiențele anterioare sau actuale ale analiștilor de credit, aceștia din urmă evaluând clienții în ceea ce privește capacitatea de rambursare a creditelor și garanțiilor. Deși aceste tehnici de judecată pot fi aplicate, instituțiile financiare utilizează mai degrabă modele de rating de credit, din necesitatea cuantificării riscului de credit. Gup și Kolar (2005) definesc *credit scoring* ca o utilizare a modelelor statistice pentru a stabili probabilitatea ca unui potențial împrumutat să nu i se mai acorde un împrumut. Potrivit aceluiași autori, modelele de rating sunt utilizate pentru a evalua împrumuturile de afaceri, imobiliarele și cheltuielile. Thomas și colab. (2002) consideră *credit scoring* drept un set de modele de decizie care îi ajută pe creditorii să acorde împrumuturi de consum: cine va primi credit, ce strategii operaționale pot crește profitabilitatea creditorilor. Crook (1996) prezintă o serie de avantaje ale *credit scoring*. Unul dintre cele mai importante avantaje este că, pentru a lua o decizie, este necesar un volum mai mic de informații, deoarece modelele de notare a creditelor au fost estimate să includă doar variabile corelate cu performanța de rambursare. În același timp, prin punctarea creditului se fac încercări de a corecta orice prejudecăți care ar putea rezulta din luarea în considerare a istoricului de rambursare numai pentru cererile aprobate.

3. Metodologia de cercetare

Metodologia de cercetare vizează o abordare deductivă care evidențiază perspectiva teoretică cu privire la conceptul IFRS 9 și o listă neexhaustivă a testelor statistice utilizate în validarea *credit scoring*. Ca metodă de cercetare poate fi menționată analiza documentelor, care constă în parcurgerea literaturii de specialitate pentru a identifica lucrările relevante pentru subiectul examinat. Au fost accesate cărți și articole din domeniu, reglementări europene și standarde internaționale de contabilitate (Standardul Internațional de Raportare Financiară 9 – *Instrumente financiare*) și, de asemenea, pagini web ale Comitetului Basel pentru supraveghere bancară și ale Autorității bancare europene.

4. Teste statistice utilizate pentru validarea Credit Scoring

4.1. Kolmogorov-Smirnov (KS)

Printre cele mai frecvent utilizate teste pentru evaluarea puterii discriminatorii a unui model se numără statistica

Kolmogorov-Smirnov (KS) prin cuantificarea distanței dintre două distribuții, observații bune și rele, conform definițiilor stabilite de instituție. Valorile KS pot varia între 0 și 1, unde 1 implică faptul că modelul este capabil să distingă cu precizie populațiile bune și rele. Prin urmare, cu cât KS este mai mare, cu atât modelul este mai bun.

Pentru fiecare debitor individual, unde este disponibil un scor S, se aplică următoarele:

Ecuția 1

$$D_K = \begin{cases} 1, & \text{clientul este bun} \\ 0, & \text{alftel} \end{cases}$$

Folosind formula menționată, se pot calcula funcțiile de distribuție cumulativă empirică (CDF) a scorurilor bune, rele sau toate:

Ecuția 2

$$F_{BUN}(a) = \frac{1}{n} \sum_{i=1}^n I(s_i \leq a | D_K = 1), \quad a \in [L, H]$$

$$F_{RĂU}(a) = \frac{1}{m} \sum_{i=1}^m I(s_i \leq a | D_K = 0), \quad a \in [L, H]$$

$$F_{TOATE}(a) = \frac{1}{n+m} \sum_{i=1}^{n+m} I(s_i \leq a), \quad a \in [L, H]$$

Unde:

s_i – Scorul debitorului i ;

n – Numărul de debitori buni;

m – Numărul de debitori răi;

I – Funcție indicator unde $I(\text{adevărat}) = 1$ și $I(\text{fals}) = 0$;

L – Valoarea minimă a scorului dat;

H – Valoarea maximă a scorului dat.

Pe baza ecuației 2, KS este definit astfel:

Ecuția 3

$$KS = \max_{a \in [L, H]} |F_{RĂU}(a) - F_{BUN}(a)|$$

Statistica KS ar trebui calculată atât pentru eşantioane de dezvoltare, cât și pentru validare. Mai mult, este de așteptat ca instituția să stabilească un cadru de monitorizare pentru a permite detectarea în timp a

oricăror degradări ale puterii discriminatorii, calculând KS pentru fiecare eşantion, valorile trimestriale putând fi evaluate în raport cu valoarea de validare inițială. În funcție de natura, dimensiunea și caracteristicile specifice portofoliului, precum și luând în considerare apetitul de risc al instituției și constrângerile de reglementare, instituția ar trebui să definească pragurile pentru testele KS. Cel mai adesea, acestea sunt asociate metaforic cu semnificația culorilor semaforului.

4.2. Curba Lorenz (LC) și Gini

Curba Lorenz (LC), Profilul de Precizie Cumulativă (CAP) sau Raportul de Precizie (AR) este un test statistic utilizat pentru a evalua puterea discriminatorie a mecanismului de clasificare a riscurilor (funcția de notare), deoarece reflectă capacitatea de a disocia între debitorii buni și răi (relația dintre funcția de distribuție cumulativă pentru debitorii buni și răi).

Primul pas al procesului este de a ordona toți debitorii pe baza scorurilor prezise de model, de la cea mai mică probabilitate, la cea mai mare. Procentul de împrumutați aflați în stadiul de nerambursare, în cadrul fiecărei benzi de probabilitate este proiectat de la probabilitatea minimă la probabilitatea maximă. Gini este definit ca raportul dintre aria generată de funcția cumulativă a modelului și funcția cumulativă a modelului aleatoriu și aria generată de funcția cumulativă a modelului perfect. Acest model ideal va oferi segregarea perfectă între grupuri, atribuind evenimente în proporția dorită în funcție de clasamentele grupurilor, cu o probabilitate mai mare de implicare pentru ratinguri, deoarece acestea sunt mai aproape de ratingul implicit.

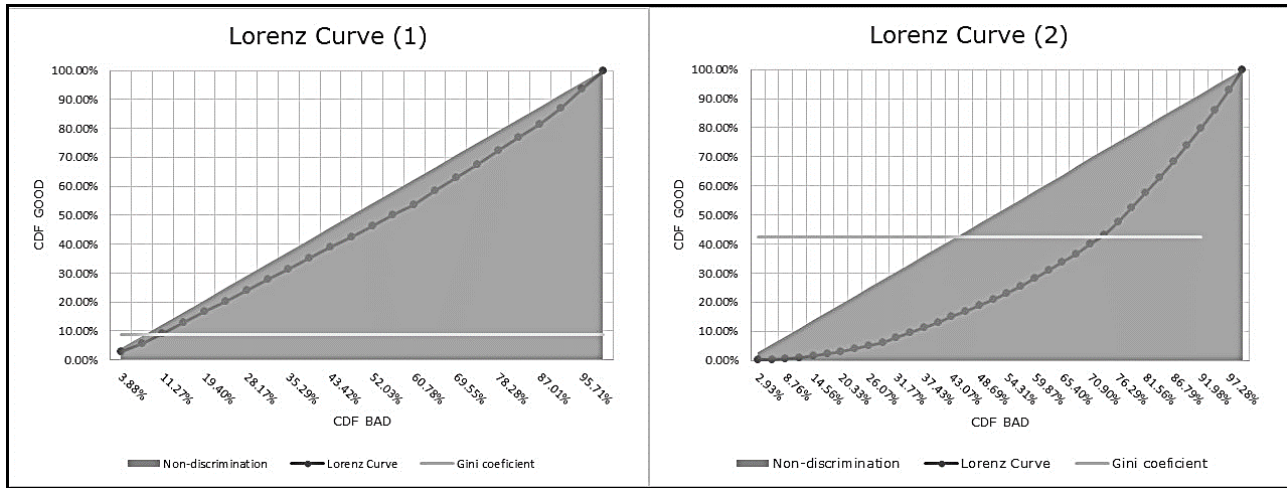
Ca și în cazul KS, funcția parametrică este definită după cum urmează:

$$x = F_{RĂU}(a), \quad a \in [L, H]$$

$$y = F_{BUN}(a), \quad a \in [L, H]$$

Figura nr. 1 prezintă rezultatele a două modele: modelul A, care avea o putere discriminatorie redusă, deoarece este mai aproape de ipotenuză, și modelul B, care are o putere discriminatorie ridicată. În cazul unui model aleatoriu (fără putere discriminatorie), curba trasată ar tăia graficul în jumătate făcând un unghi de 45 de grade cu axele carteziene, în timp ce un model perfect ar prezenta o curbă care va delimita exact cele două adiacente ale triunghiului.

Figura nr. 1. Curba Lorenz



Sursa: Prelucrare autori, 2021

Indicele Gini descrie calitatea generală a funcției de notare a mecanismului de clasificare a riscurilor, care ia valori între -1 și 1 în cadrul modelului ideal, funcția de notare separă debitorii buni și răi, prin urmare Gini este aproape de 1, în timp ce un model aleator care atribuie un scor aleator prezintă Gini aproape de 0. În cazul valorilor Gini negative, valorile corespund unui model cu semnificație inversă a scorurilor (Anexa 1 pentru datele de bază și calcul).

Gini se calculează luând în considerare distribuțiile cumulative continue rele și bune ($F_{R\ddot{A}U}$) (F_{BUN}):

Ecuția 4

$$Gini = 2 \int_0^1 F_{R\ddot{A}U} dF_{BUN} - 1$$

Pentru o aproximare discretă se utilizează regula trapezoidală sau regula lui Simpson:

$$Gini \approx \sum_{k=1}^N [(F_{R\ddot{A}U_k} + F_{R\ddot{A}U_{k-1}}) * (F_{BUN_k} - F_{BUN_{k-1}})] - 1$$

Unde N este numărul de observații ale distribuțiilor RĂU și BINE analizate.

După cum s-a menționat anterior, testele ar trebui să fie efectuate pe probele de dezvoltare și validare. Se așteaptă o degradare a rezultatelor lor, în special pentru eşantioanele utilizate în etapa de prevedere a caracteristicilor de referință pentru eşantioanele examinate și eşalonate, dar diferențele ar trebui să se încadreze în nivelul de toleranță acceptat. Prin urmare, instituțiile ar trebui să stabilească un cadru de monitorizare pentru a identifica etapele timpurii ale deteriorării. Se recomandă efectuarea testului atât în scopuri de monitorizare, cât și validare anuală. Pragurile pentru test trebuie stabilite în conformitate cu specificul portofoliului; se așteaptă valori mai mici pentru portofoliul de corporații și IMM-uri decât pentru portofoliile de imobiliare.

4.3. Curba Caracteristică de Funcționare a Receptorului (ROC)

Curba caracteristică de funcționare a receptorului (ROC) descrie relația dintre complementele a două funcții de distribuție cumulativă empirică (CDF). Având în vedere două variabile aleatoare continue, X și Y, un punct pe un grafic al unei curbe ROC este situat la $P(X \geq p)$ pe axa orizontală și la $P(Y \geq p)$ pe axa verticală, unde „p” este o constantă care poate lua valori în domeniul X și Y. În raport cu curba ROC sunt definite următoarele concepte:

- Rata pozitivă adevărată – rata de lovire (HR) reprezintă sensibilitatea sau evenimentele identificate corect;

- Rata negativă adevărată – specificitatea reprezintă non-evenimentele identificate corect;
- Rata falsă negativă –1- specificitatea reprezintă rata de alarmă falsă (FAR);
- Rata falsă pozitivă –1- sensibilitate.

Curba ROC este obținută prin reprezentarea HR față de FAR pentru diferite valori de „p”. Prin urmare, curba ROC apropiată de diagonală (linia de nediscriminare), indică un model aleatoriu, în timp ce o curbă aproape de colțul din stânga sus prezintă un model cu o putere discriminatorie mare, prin urmare, cu cât suprafața sub curba ROC este mai mare, cu atât este mai bun modelul.

Acest lucru duce la un alt test pentru evaluarea puterii discriminatorii a modelului: aria aflată sub curbă (AUC sau AUROC) numită și coeficient de concordanță (c). O valoare de 0,5 reprezintă un model aleatoriu, în timp ce o valoare de 1 indică faptul că respectiva curbă ROC se află în colțul din stânga sus, iar modelul discriminează perfect.

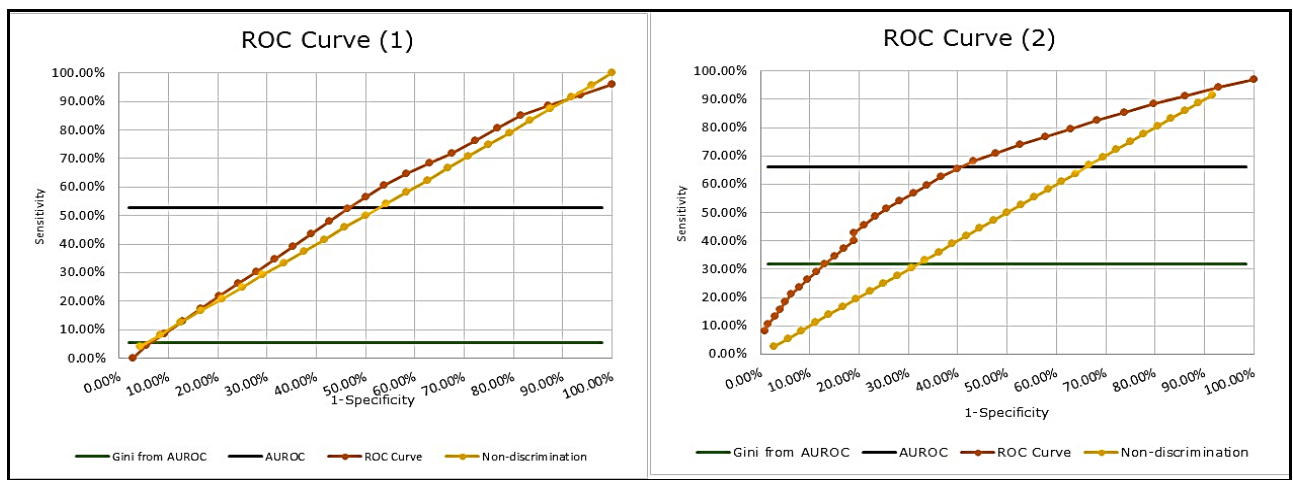
Gini poate fi exprimat ca AUROC:

Ecuția 5

$$Gini = 2 * AUROC - 1$$

Graficele din **Figura nr. 2** descriu două curbe ROC; cea din dreapta relevă o putere de discriminare mai mare pentru modelul său de bază decât cea din stânga.

Figura nr. 2. Curba ROC



Sursa: Prelucrare autori, 2021

Pentru un rezultat exact, se recomandă calculul integral; totuși regula trapezoidală sau a lui Simpson poate fi utilizată pentru a aproxima AUROC:

$$AUROC_{teoretic} = 1 - \frac{1}{\bar{D}(N - \bar{D})} \sum_{i=1}^K (N_i - \bar{D}_i) \left(\frac{\bar{D}_i}{2} + \sum_{j=1}^{i-1} \bar{D}_j \right)$$

Unde:

N – Numărul de clienți din portofoliu la începutul perioadei de observare;

K – Notele de rating pentru expunerile neimplicate;

N_i – Numărul de clienți în gradul I de rating;

PD_i – PD folosit pentru a estima valorile implicite viitoare pentru gradul I de rating;

$\bar{D}_i = [N_i * PD_i]$ – Numărul estimat de prestabilitate pentru clasa I de rating, unde „[.]” reprezintă cel mai apropiat număr întreg;

$\bar{D} = \sum_{i=1}^K \bar{D}_i$ – Numărul total estimat de valori implicite.

După cum se poate observa din exemplul prezentat mai sus, modelul utilizat pentru a genera Curba 2 are o performanță mai bună decât cel folosit pentru a genera Curba 1.

4.4. Somers' D (Ds)

Somers' D este o măsură ce indică ordinea care poate fi definită în termenii lui Kendall's τ_a . Trebuie menționat că indicele Gini este un caz special al lui Somers' D.

Având în vedere o succesiune de variabile aleatoare bivariate $(X, Y) = \{(X_i, Y_i)\}$ Kendall's τ_a este definit ca:

$$\tau(X, Y) = E[\text{sign}(X_i - X_j)\text{sign}(Y_i - Y_j)]$$

Unde:

$E[\cdot]$ - denotă estimarea;

(X_i, Y_i) și (X_j, Y_j) : reprezintă variabilele aleatoare bivariate extrase independent din același eșantion pentru modelele PD $X = 1$ bune și $X = 0$ dacă rele, Y reprezintă scoruri.

Kendall's τ_a ne arată diferența dintre probabilitatea ca cele două perechi (X, Y) să fie concordante și probabilitatea ca cele două perechi (X, Y) să fie discordante.

Somers' D, la un model dat de credit scoring, notat ca D_s , se calculează după cum urmează:

$$D_s = \frac{\sum_i g_i \sum_{j < i} b_j - \sum_i g_i \sum_{j > i} b_j}{n * m}$$

Unde:

$g_i(b_j)$ - este numărul de bune/rele în intervalul de scoruri i^{th}

n – numărul de „bune”;

m – numărul de „rele”.

Cu alte cuvinte, într-o manieră mai puțin matematică, Somers'D se definește astfel:

$$D_s = \frac{\text{Concordant Pairs} - \text{Discordant Pairs}}{\text{Total Number of Pairs Including Ties}}$$

O altă modalitate de a calcula D_s este prin statistica U a lui Mann-Whitney. Pentru a calcula această statistică, eșantionul trebuie să fie ordonat în mod crescător în funcție de valoarea scorului.

D_s este dat de:

$$D_s = 2 * \frac{U}{n * m} - 1$$

Unde U este dat de $U = R_G - \frac{1}{2} * n * (n + 1)$.

Din punct de vedere matematic, Somers' D este egal cu indicele Gini. Cu toate acestea, datorită faptului că Somers' D este mai complex (dimensiunea portofoliului definește numărul de perechi potențiale bune/rele) și nu poate fi aproximată corespunzător, Gini este utilizat mai frecvent. Somers' D este analiza efectuată cu ajutorul software-ului furnizat de SAS, utilizat în mod obișnuit în multe instituții financiare.

4.5. Information value (IV)

Atunci când se modelează un scorecard, statistica Value Information (IV) este o metodă populară pentru selectarea variabilelor predictive. Având în vedere starea de nerambursare, poate fi modelată ca un rezultat binar, IV este o modalitate bună de a evalua puterea predictorului.

Ținând cont de faptul că obiectivul este binar, atunci când se construiesc variabile explicative pentru dezvoltarea unui tablou de bord, variabilele continue nu pot fi validate cu ușurință. Astfel, toate observațiile ale fiecărui predictor X trebuie grupate. Numărul de note ar trebui să asigure că relația dintre variabila explicativă și variabila țintă este relevantă. După eliminarea valorilor aberante și identificarea tendințelor, IV scade odată cu scăderea notelor.

4.6. Herfindhal-Hirschman Index (HHI)

Modelele de portofoliu de credite trebuie să asigure omogenitatea expunerilor în același grad și omogenitate între note. Indicele Herfindhal-Hirschman (HHI) se numără printre cele mai frecvente teste utilizate pentru a se asigura că segmentarea portofoliului este adecvată; niciuna dintre note nu prezintă o valoare ridicată:

$$HHI = \sum_{i=1}^n \gamma_i^2$$

Unde:

n – numărul de expuneri din portofoliu;

γ_i – expunerea facilității „ i ” în raport cu valoarea totală a portofoliului.

Formula de mai sus este aplicată la nivel de portofoliu. Cu toate acestea, pentru a identifica valoarea mare / scăzută în cadrul fiecărei note, trebuie aplicată următoarea formulă: HHI pentru a crește, este util să

aveți o viziune segmentată. Având în vedere probabilitatea matematică, se poate presupune că portofoliul este împărțit în „m” grupuri.

$$HHI = \sum_{k=1}^m F_k^2 H_k$$

Unde:

M – numărul de note;

F_k – numărul de expuneri ale notei “k” în raport cu valoarea totală a portofoliului;

H_k – HHI în fiecare grup.

HHI poate fi utilizat pentru a evalua valoarea distribuției debitorilor în note sau scoruri. În primul rând se calculează un coeficient de variație, apoi indicele Herfindahl:

$$CV_{curr} = \sqrt{K \sum_{i=1}^K \left(R_i - \frac{1}{K}\right)^2}$$

$$HHI = \frac{CV_{curr}^2 + 1}{K}$$

Unde:

K – Numărul de note de rating pentru expunerile neimplicite;

R_i – Frecvența relativă a calificativului „i” la începutul perioadei relevante de observație.

4.7. Bootstrap validation

În cazul în care instituția are un eșantion redus sau o perioadă scurtă de observație Bootstrapping este utilizat pentru a simula caracteristica „în afara eșantionului” a populației de credite. Bootstrap poate acționa ca o metodă de eșantionare, dar și ca o condiție prealabilă a cadrului de validare în conformitate cu legea numărului mare și nu poate fi considerată o metodă de validare independentă.

După eșantionare, având în vedere existența datelor suficiente și concordanța între testul de validare și metoda de estimare, se pot calcula toate celelalte teste statistice (Gini, KS, AUROC, Binom etc.). Astfel, putem afirma că bootstrap este o metodă adecvată utilizării în diferite situații. Principalul dezavantaj al bootstrapping-ului este că adesea are o metodă de calcul costisitoare.

5. Concluzii

Lucrarea de față prezintă tehnicile cantitative cheie pe care instituțiile ar trebui să le utilizeze pentru a evalua adecvarea cadrului său de *credit scoring* pentru atribuirea notelor expunerilor și, de asemenea, beneficiile *credit scoring*-ului. Studiul prezintă teste pe care instituțiile ar fi necesar să le folosească pentru a evalua predictiv modelele sale și cât de reprezentativă este populația de expuneri pe care a fost dezvoltat modelul față de populația de expuneri la care se aplică modelul. Cu toate acestea, nu este suficient doar ca instituțiile să efectueze aceste teste, ci trebuie, de asemenea, să se asigure că au praguri adecvate pentru a identifica când un model ratează aceste teste și să se asigure că sunt întreprinse acțiuni adecvate pentru remedierea situației în care un model eșuează la test. Unde este posibil, testele prezentate în această secțiune ar trebui să fie aplicate la nivel de factor, precum și la nivelul general al notei, pentru a permite instituției să identifice orice deteriorare a performanței într-un factor individual, care poate să nu fie evidentă atunci când testele sunt efectuate la un nivel global de rating al creditului. În cele din urmă, aceste teste prezintă maximă importanță în determinarea adecvării gradului de ordonare a notelor de credit, totuși nu evaluează adecvarea cuantificării estimărilor provizioanelor. Acestea ar trebui să fie evaluate la un nivel global al parametrilor PD, după ce modelul a fost calibrat la un an PD PIT pentru estimările etapei 1 și PD pe durata de viață pentru estimările etapei 2.

Avantajele *credit scoring* sunt următoarele: necesită mai puține informații pentru a lua o decizie, deoarece modelele au fost estimate să ia în considerare doar acele variabile care sunt corelate statistic cu performanța de rambursare. Modelele de notare a creditelor iau în considerare atât aspectele debitorilor buni, cât și cei răi. Modelele de *credit scoring* au la bază o perioadă lungă de timp și o bază largă de informații referitoare la eșantioane, comparativ cu memoria unui analist.

BIBLIOGRAFIE

1. Basel committee on banking supervision (2015), Guidance on credit risk and accounting for expected credit losses, <https://www.bis.org/bcbs/publ/d350.pdf>
2. Borio C., Lowe P. (2001), To provision or not to provision, *BIS Quarterly Review*, Vol. 9, Nr. 3, pp. 36-48.
3. Bushman R.M., Williams C.D. (2015), Delayed expected loss recognition and the risk profile of banks, *Journal of Accounting Research*, Vol. 53, Nr. 3, pp. 511-553.
4. Carlehed M., Petrov A. (2012), A methodology for point-in-time-through-the-cycle probability of default decomposition in risk classification systems, *Journal of Risk Model Validation*, Vol. 6, Nr. 3, pp. 3-25.
5. Chawla, G., Forest L.R., Aguais S.D. (2016), Point-in-time loss-given default rates and exposures at default models for IFRS 9/CECL and stress testing, *Journal of Risk Management in Financial Institutions*, Vol. 9, Nr. 3, pp. 249-263.
6. Crook, J. N. (1996), Credit scoring: An overview. *Working paper series No. 96/13, British Association, Festival of Science. University of Birmingham, The University of Edinburgh.*
7. European Banking Authority (2017), Guidelines on credit institutions' credit risk management practices and accounting for expected credit losses, <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1842525/d769d006-d992-4202-8838-711a034e80a2/Final%20Guidelines%20on%20Accounting%20for%20Expected%20Credit%20Losses%20%28EBA-GL-2017-06%29.pdf>
8. European Banking Authority (2017), Guidelines on PD estimation, LGD estimation and the treatment of defaulted exposures, <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/2033363/6b062012-45d6-4655-af04-801d26493ed0/Guidelines%20on%20PD%20and%20LGD%20estimation%20%28EBA-GL-2017-16%29.pdf?retry=1>
9. European Banking Authority (2016), Guidelines on the application of the definition of default under Article 178 of Regulation (EU) No. 575/2013, <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1597103/004d3356-a9dc-49d1-aab1-3591f4d42cbb/Final%20Report%20on%20Guidelines%20on%20default%20definition%20%28EBA-GL-2016-07%29.pdf?retry=1>
10. Global Public Policy Committee (2016), The implementation of IFRS 9 impairment requirements by banks, <https://www.iasplus.com/en/publications/global/other/ifrs-9-impairment-banks>
11. Gordy, M. (2003), A Risk-Factor Model Foundation for Ratings-Based Bank Capital Rules, *Journal of Financial Intermediation*, Vol. 12, pp. 199-232.
12. Gordy, M. (2000), A Comparative Anatomy of Credit Risk Models, *Journal of Banking and Finance*, Vol. 24, pp. 119-149.
13. Gup, B. E., Kolari, J. W. (2005), Commercial Banking: The management of risk. *Alabama: John Wiley&Sons, Inc.*
14. Hamerle, A., Liebig T., Rosch D. (2003), Benchmarking Asset Correlations Risk, Vol. 16, pp. 77-81.
15. Heitfield, A. (2005), Dynamics of Rating Systems, in: Basel Committee on Banking Supervision: Studies on the Validation of Internal Rating Systems, *Working Paper No. 14*, February, pp. 10-27.
16. Gebhardt, G.U., Novotny-Farkas, Z. (2011), Mandatory IFRS adoption and accounting quality of European banks, *Journal of Business Finance&Accounting*, Vol. 38, Nr.3-4, pp. 289-333.
17. International accounting standards Board (2014), International Financial reporting standard 9 Financial instruments, <https://www.ifrs.org/issued-standards/list-of-standards/ifrs-9-financial-instruments/>
18. Novotny-Farkas, Z. (2016), The interaction of the IFRS 9 expected loss approach with supervisory rules and implications for financial stability, *Accounting in Europe*, Vol. 13, Nr. 2, pp. 197-227.
19. Onali, E., Ginesti, G. (2014), Pre-adoption market reaction to IFRS 9: a cross-country event-study, *Journal of Accounting and Public Policy*, Vol. 33, Nr. 6, pp. 628-637.
20. Peduzzi, P., Concato, J., Feinstein, A.R., Holford, T.R. (1995), Importance of events per independent variable in proportional hazards regression analysis II. Accuracy and precision of regression estimates, *Journal of Clinical Epidemiology*, Vol. 48, Nr. 12, pp. 1503-1510.
21. Pool, S., De Haan, L., Jacobs, J.P. (2015), Loan loss provisioning, bank credit and the real economy, *Journal of Macroeconomics*, Vol. 45, Nr. 1, pp. 124-136.
22. Reitgruber, W. (2016), Expected loss provisioning under upcoming IFRS 9 impairment standards: a

- new source of P&L volatility – Can we tame it?, *Journal of Risk Management in Financial Institutions*, Vol. 9, Nr. 4, pp. 332-343.
24. Sarlija, N., Bencic M., Bohacek Z. (2004), Multinomial Model in Consumer Credit Scoring, *10th International Conference on Operational Research*.
25. Skoglund, J. (2017), Credit risk term-structures for life time impairment forecasting: a practical guide, *Journal of Risk Management in Financial Institutions*, Vol. 10, Nr. 2, pp. 177-195.
26. Thomas, L. C., Edelman, D. B., Crook, L. N. (2002), *Credit Scoring and Its Applications*. Philadelphia: Society for Industrial and Applied Mathematics.
27. Yang, B.H. (2017), Point-in-time PD term structure models for multi-period scenario loss projection: methodologies and implementations for IFRS 9 ECL and CCAR stress testing, *Journal of Risk Model Validation*, Vol. 11, Nr. 3, pp. 1-17.

Anexa 1 – Curba Lorenz și date ROC

Generarea curbei 1 – Datele utilizate sunt generate aleatoriu, pentru a ilustra un sistem de clasare compus din 24 de grade

Rating	Ascending BAD						
	GRADE	GOOD	BAD	PDF_BAD	CDF_BAD	PDF_GOOD	CDF_GOOD
A	1	162	3	2.78%	2.78%	3.88%	3.88%
	2	157	3	2.78%	5.56%	3.76%	7.65%
	3	151	4	3.70%	9.26%	3.62%	11.27%
	4	155	4	3.70%	12.96%	3.72%	14.98%
	5	184	4	3.70%	16.67%	4.41%	19.40%
	6	184	4	3.70%	20.37%	4.41%	23.81%
B	7	182	4	3.70%	24.07%	4.36%	28.17%
	8	147	4	3.70%	27.78%	3.52%	31.70%
	9	150	4	3.70%	31.48%	3.60%	35.29%
	10	168	4	3.70%	35.19%	4.03%	39.32%
	11	171	4	3.70%	38.89%	4.10%	43.42%
	12	178	4	3.70%	42.59%	4.27%	47.69%
C	13	181	4	3.70%	46.30%	4.34%	52.03%
	14	182	4	3.70%	50.00%	4.36%	56.39%
	15	183	4	3.70%	53.70%	4.39%	60.78%
	16	182	5	4.63%	58.33%	4.36%	65.14%
	17	184	5	4.63%	62.96%	4.41%	69.55%
	18	180	5	4.63%	67.59%	4.32%	73.87%
D	19	184	5	4.63%	72.22%	4.41%	78.28%
	20	184	5	4.63%	76.85%	4.41%	82.69%
	21	180	5	4.63%	81.48%	4.32%	87.01%
	22	182	6	5.56%	87.04%	4.36%	91.37%
	23	181	7	6.48%	93.52%	4.34%	95.71%
	24	179	7	6.48%	100.00%	4.29%	100.00%

GRADE	CDF_GOOD	CDF_BAD	Lorenz Curve	Gini coeficient	KS statistic
1	3.88%	2.78%	0.00%	8.73%	7.07%
2	7.65%	5.56%	0.16%	8.73%	7.07%
3	11.27%	9.26%	0.43%	8.73%	7.07%
4	14.98%	12.96%	0.84%	8.73%	7.07%
5	19.40%	16.67%	1.49%	8.73%	7.07%
6	23.81%	20.37%	2.31%	8.73%	7.07%
7	28.17%	24.07%	3.28%	8.73%	7.07%
8	31.70%	27.78%	4.19%	8.73%	7.07%
9	35.29%	31.48%	5.26%	8.73%	7.07%
10	39.32%	35.19%	6.60%	8.73%	7.07%
11	43.42%	38.89%	8.12%	8.73%	7.07%
12	47.69%	42.59%	9.86%	8.73%	7.07%
13	52.03%	46.30%	11.79%	8.73%	7.07%
14	56.39%	50.00%	13.89%	8.73%	7.07%
15	60.78%	53.70%	16.16%	8.73%	7.07%
16	65.14%	58.33%	18.61%	8.73%	7.07%
17	69.55%	62.96%	21.28%	8.73%	7.07%
18	73.87%	67.59%	24.10%	8.73%	7.07%
19	78.28%	72.22%	27.18%	8.73%	7.07%
20	82.69%	76.85%	30.47%	8.73%	7.07%
21	87.01%	81.48%	33.89%	8.73%	7.07%
22	91.37%	87.04%	37.56%	8.73%	7.07%
23	95.71%	93.52%	41.48%	8.73%	7.07%
24	100.00%	100.00%	45.63%	8.73%	7.07%

Pentru generarea Curbei 2 a fost utilizat un portofoliu simulat aleatoriu. Portofoliul a fost grupat în 36 de clase, după cum urmează:

Rating	Ascending BAD						
	GRADE	GOOD	BAD	PDF_BAD	CDF_BAD	PDF_GOOD	CDF_GOOD
A	1	422	4	0.05%	0.05%	2.93%	2.93%
	2	421	12	0.15%	0.20%	2.92%	5.85%
	3	419	24	0.30%	0.50%	2.91%	8.76%
	4	418	36	0.45%	0.94%	2.90%	11.67%
	5	417	44	0.55%	1.49%	2.90%	14.56%
	6	416	56	0.69%	2.18%	2.89%	17.45%
B	7	415	64	0.79%	2.98%	2.88%	20.33%
	8	414	76	0.94%	3.92%	2.87%	23.21%
	9	413	84	1.04%	4.96%	2.87%	26.07%
	10	411	104	1.29%	6.25%	2.85%	28.93%
	11	409	124	1.54%	7.79%	2.84%	31.77%
	12	408	136	1.69%	9.47%	2.83%	34.60%
C	13	407	144	1.79%	11.26%	2.83%	37.43%
	14	407	144	1.79%	13.05%	2.83%	40.25%
	15	405	156	1.93%	14.98%	2.81%	43.07%
	16	405	160	1.98%	16.96%	2.81%	45.88%
	17	405	164	2.03%	19.00%	2.81%	48.69%
	18	405	164	2.03%	21.03%	2.81%	51.50%
D	19	404	172	2.13%	23.16%	2.81%	54.31%
	20	401	196	2.43%	25.60%	2.78%	57.09%
	21	400	212	2.63%	28.22%	2.78%	59.87%
	22	398	224	2.78%	31.00%	2.76%	62.63%
	23	398	224	2.78%	33.78%	2.76%	65.40%
	24	398	224	2.78%	36.56%	2.76%	68.16%
E	25	394	264	3.27%	39.83%	2.74%	70.90%
	26	393	276	3.42%	43.25%	2.73%	73.63%
	27	384	360	4.46%	47.72%	2.67%	76.29%
	28	380	396	4.91%	52.63%	2.64%	78.93%
	29	378	416	5.16%	57.79%	2.62%	81.56%
	30	378	416	5.16%	62.95%	2.62%	84.18%
F	31	376	436	5.41%	68.35%	2.61%	86.79%
	32	376	436	5.41%	73.76%	2.61%	89.40%
	33	371	484	6.00%	79.76%	2.58%	91.98%
G	34	378	514	6.37%	86.14%	2.62%	94.60%
	35	385	544	6.75%	92.88%	2.67%	97.28%
	36	392	574	7.12%	100.00%	2.72%	100.00%

GRADE	CDF_GOOD	CDF_BAD	Lorenz Curve	Gini coeficient	KS statistic
1	2.93%	0.05%	0.00%	42.40%	31.65%
2	5.85%	0.20%	0.00%	42.40%	31.65%
3	8.76%	0.50%	0.01%	42.40%	31.65%
4	11.67%	0.94%	0.03%	42.40%	31.65%
5	14.56%	1.49%	0.07%	42.40%	31.65%
6	17.45%	2.18%	0.12%	42.40%	31.65%
7	20.33%	2.98%	0.20%	42.40%	31.65%
8	23.21%	3.92%	0.30%	42.40%	31.65%
9	26.07%	4.96%	0.42%	42.40%	31.65%
10	28.93%	6.25%	0.58%	42.40%	31.65%
11	31.77%	7.79%	0.78%	42.40%	31.65%
12	34.60%	9.47%	1.03%	42.40%	31.65%
13	37.43%	11.26%	1.32%	42.40%	31.65%
14	40.25%	13.05%	1.66%	42.40%	31.65%
15	43.07%	14.98%	2.06%	42.40%	31.65%
16	45.88%	16.96%	2.51%	42.40%	31.65%
17	48.69%	19.00%	3.01%	42.40%	31.65%
18	51.50%	21.03%	3.58%	42.40%	31.65%
19	54.31%	23.16%	4.20%	42.40%	31.65%
20	57.09%	25.60%	4.87%	42.40%	31.65%
21	59.87%	28.22%	5.62%	42.40%	31.65%
22	62.63%	31.00%	6.44%	42.40%	31.65%
23	65.40%	33.78%	7.34%	42.40%	31.65%
24	68.16%	36.56%	8.31%	42.40%	31.65%
25	70.90%	39.83%	9.35%	42.40%	31.65%
26	73.63%	43.25%	10.49%	42.40%	31.65%
27	76.29%	47.72%	11.70%	42.40%	31.65%
28	78.93%	52.63%	13.02%	42.40%	31.65%
29	81.56%	57.79%	14.47%	42.40%	31.65%
30	84.18%	62.95%	16.06%	42.40%	31.65%
31	86.79%	68.35%	17.77%	42.40%	31.65%
32	89.40%	73.76%	19.63%	42.40%	31.65%
33	91.98%	79.76%	21.60%	42.40%	31.65%
34	94.60%	86.14%	23.78%	42.40%	31.65%
35	97.28%	92.88%	26.17%	42.40%	31.65%
36	100.00%	100.00%	28.80%	42.40%	31.65%