

Quantification du risque de crédit : évolution de paradigme et perspectives d'application dans le contexte algérien

Quantification of Credit Risk: Paradigm shift and application prospects in the Algerian context

KACI Amel

Ecole Supérieure de Commerce (Algérie)

kaciamelkaci@gmail.com

Résumé:

Cet article présente une revue de littérature critique sur la quantification du risque de crédit bancaire. Il retrace l'évolution des modèles classiques vers les approches modernes dont l'usage soulève le défi clé de l'explicabilité face aux exigences réglementaires. La réflexion est transposée au contexte algérien pour examiner ensuite les défis majeurs liés à la gouvernance des données, à la transition réglementaire vers les standards bâlois sous la supervision du régulateur et à l'implémentation d'infrastructures analytiques modernes.

informations sur l'article

Reçu

02/08/2026

Acceptation

11/10/2026

Mots clés:

- ✓ Risque de crédit
- ✓ Apprentissage supervisé
- ✓ Système bancaire algérien

Abstract :

This article presents a critical literature review on the quantification of banking credit risk. It traces the evolution from traditional models to modern approaches, the use of which raises the key challenge of explainability in the face of regulatory requirements. The discussion is then transposed to the Algerian context to examine the major challenges related to data governance, the regulatory transition toward Basel standards under the supervisor's oversight, and the implementation of modern analytical infrastructures.

Article info

Received

02/08/2026

Accepted

11/10/2026

Keywords:

- ✓ Credit Risk
- ✓ Machine Learning
- ✓ Algerian Banking System

INTRODUCTION

Le risque de crédit, défini comme la probabilité qu'une contrepartie financière ou un débiteur ne formule pas les flux contractuels dus à leurs échéances fixées, constitue historiquement et structurellement la menace la plus critique pesant sur la solvabilité des banques de dépôts et sur la stabilité financière globale. L'histoire macroéconomique contemporaine, jalonnée par la crise des subprimes en 2008 ou plus récemment par les réajustements post-pandémiques, démontre avec acuité que les défaillances de modélisation du risque de crédit agissent comme des vecteurs systémiques de contagion. Dans ce contexte, la capacité des banques commerciales à anticiper, quantifier et tarifier le risque d'insolvabilité de manière fine n'est plus seulement un avantage compétitif, mais une condition fondamentale de viabilité institutionnelle.

Sous l'impulsion du Comité de Bâle, la réglementation prudentielle internationale a progressivement imposé une architecture quantitative rigoureuse. Le passage de Bâle I à Bâle II, puis le déploiement de Bâle III ont marqué un glissement d'une logique forfaitaire de couverture des risques vers une sensibilité accrue aux risques réels des portefeuilles, matérialisée par l'approche fondée sur les notations internes. Cette réglementation exige des établissements de crédit qu'ils estiment eux-mêmes les paramètres pivots du risque : la probabilité de défaut (PD), la perte en cas de défaut (LGD) et l'exposition au moment du défaut (EAD). Dès lors, la précision des modèles mathématiques et statistiques est devenue un enjeu de premier ordre pour optimiser l'allocation des fonds propres réglementaires.

Pendant plusieurs décennies, la recherche académique et la pratique bancaire se sont articulées autour de deux visions théoriques prédominantes. D'une part, l'approche structurelle issue de la thèse de Merton (1974) qui mobilise le calcul stochastique et la théorie des options pour lier mathématiquement le défaut à l'évolution de la valeur des actifs de l'entreprise par rapport à sa structure de dette. D'autre part, l'approche en forme réduite (Jarrow & Turnbull, 1995 ; Duffie & Singleton, 1999) qui rejette la modélisation endogène des causes de la faillite pour traiter le défaut comme un événement de surprise exogène régi par un processus de saut de Poisson.

Parallèlement à ces approches micro-quantitatives, les banques de détail ont massivement adopté la régression logistique à travers les techniques de credit scoring pour évaluer le segment des particuliers et des PME. Bien que robustes et facilement interprétables par les auditeurs et superviseurs, ces approches traditionnelles se heurtent à des limites conceptuelles sévères lorsqu'elles font face à des données massives, asymétriques, bruitées et non linéaires. Elles exigent des hypothèses restrictives (absence de colinéarité, spécification fonctionnelle a priori, normalité) qui reflètent imparfaitement la complexité des comportements de défaut en période de crise ou d'instabilité macroéconomique.

C'est dans cette faille méthodologique que s'est inséré le paradigme du Machine Learning (ML) et de l'Intelligence Artificielle (IA). Libérés des contraintes paramétriques, les algorithmes d'apprentissage supervisé, tels que les forêts aléatoires, les architectures de boosting de gradient ou les réseaux de neurones profonds démontrent une supériorité métrique incontestable pour détecter des signaux faibles et appréhender les interactions complexes entre variables macroéconomiques et ratios financiers. Cependant, cette puissance prédictive soulève un défi

majeur : l'explicabilité du modèle. Le dilemme de la « boîte noire » freine l'adoption réglementaire globale de ces outils, incitant la recherche actuelle à développer des méthodes de confiance pour rendre ces algorithmes transparents.

Pour les économies en transition ou en développement, à l'instar de l'Algérie, l'assimilation de cette trajectoire scientifique pose des défis d'une complexité particulière. Le système bancaire algérien, largement dominé par les institutions publiques, évolue dans un environnement financier intermédié où le marché des capitaux demeure embryonnaire. La gestion du risque y est traditionnellement adossée à une logique de garanties réelles (sûretés et hypothèques) et l'application des accords de Bâle y suit un rythme progressif géré par la Banque d'Algérie. Dès lors, comment concilier le retard infrastructurel en matière de gouvernance des données et l'avènement mondial d'outils d'intelligence artificielle pour la quantification des risques ? L'Algérie doit-elle forcer une transition linéaire par les étapes bâloises classiques ou peut-elle opérer un saut technologique direct en adoptant le Machine Learning pour sa notation interne ?

L'objectif de cet article est d'apporter une contribution théorique et contextuelle à cette problématique en articulant notre réflexion autour de trois axes fondamentaux : 1. Une revue critique approfondie des fondements mathématiques des modèles traditionnels (structurels et forme réduite). 2. Une analyse de l'adaptation méthodologique requise par le paradigme du Machine Learning, en explicitant le fonctionnement des algorithmes et la résolution du dilemme performance-explicabilité. 3. Une confrontation de ces mutations scientifiques au cadre empirique du secteur bancaire algérien, afin d'identifier les barrières structurelles et de proposer une feuille de route pour une modernisation durable.

2 Fondements mathématiques et limites des modèles traditionnels

2.1 L'approche structurelle : le modèle de Merton (1974)

L'école structurelle repose sur l'analogie conceptuelle entre la structure de capital d'une entreprise et les options financières. Le défaut y est considéré comme un événement prévisible que l'on peut anticiper en observant l'évolution de la valeur des actifs de l'entreprise pour évaluer sa solvabilité.

L'hypothèse de départ stipule qu'une entreprise finance ses opérations par deux instruments : des capitaux propres (E) et une dette zéro-coupon de valeur nominale K arrivant à échéance à un horizon fixe T . On désigne par (V_t) la valeur marchande totale des actifs de la firme à l'instant t . Sous le cadre de Merton (1974), la dynamique temporelle de (V_t) est modélisée par un mouvement brownien géométrique sous la probabilité historique $\mathbb{P}$:

$$dV_t = \mu V_t dt + \sigma V_t W_t$$

où μ représente le taux de rendement instantané attendu des actifs de la firme, σ correspond à la volatilité instantanée de la valeur des actifs (supposée constante), et W_t est un processus de Wiener standard (mouvement brownien standard) par rapport à la filtration $\mathcal{F}_t$.

Le défaut d'une telle entité ne peut survenir qu'à l'échéance T si la valeur des actifs (V_t) est strictement inférieure à l'engagement nominal K : $V_t < K$. En vertu du principe de responsabilité

limitée, les actionnaires cèdent l'intégralité des actifs aux créanciers. À l'inverse, si $V_t > K$, les créanciers perçoivent le montant nominal K et les actionnaires conservent le reliquat, soit $V_t - K$. les capitaux propres s'assimilent ainsi au payoff d'une option d'achat (Call) européenne sur les actifs de l'entreprise, de prix d'exercice K :

$$E_t = \max (V_t - K, 0)$$

Sous la mesure du risque-neutre Q , la formule de Black-Scholes (1973) donne la valeur des fonds propres E_t à $t < T$:

$$E_t = V_t N(d_1) - K e^{-r(T-t)} N(d_2)$$

Avec :

$$d'_1 = \frac{\ln\left(\frac{V_T}{K}\right) + \left(r + \frac{\sigma^2}{2}\right)(T-t)}{\sigma\sqrt{T-t}} \quad \text{et} \quad d_2 = d_1 - \sigma\sqrt{T-t}$$

Sous la mesure historique P , la Probabilité de Défaut (PD) théorique correspond à la probabilité que la valeur finale des actifs soit inférieure au seuil de dette K :

$$P(V_T < K) = N(-d'_2)$$

Où la variable d'_2 , ajustée avec le taux de rendement historique μ au lieu du taux sans risque r , définit la Distance au Défaut (DD), indicateur important utilisé par des agences spécialisées notamment le modèle d'évaluation de KMV de Moody's.

$$DD = d'_2 = \frac{\ln\left(\frac{V_T}{K}\right) + \left(\mu - \frac{\sigma^2}{2}\right)(T-t)}{\sigma\sqrt{T-t}}$$

L'application pratique du modèle de Merton se heurte à des limites structurelles bien documentées dans la littérature financière, essentiellement : **1. Inobservabilité des variables pivots** : Contrairement au cours d'une action, la valeur totale de marché des actifs d'une firme (V_t) et sa volatilité associée (σ) ne sont pas directement observables sur le marché, en particulier pour les entreprises non cotées qui forment la quasi-totalité du tissu économique en Algérie. **2. Hypothèse de défaut à l'échéance uniquement** : Le modèle suppose que le défaut ne peut survenir qu'à la date fixe T . En réalité, une entreprise peut faire faillite à tout instant si ses flux de trésorerie deviennent insuffisants pour honorer un paiement d'intérêts ou de dettes de court terme. **3. Structure de dette simpliste** : La modélisation suppose une dette unique de type zéro-coupon, ce qui est très éloigné de la complexité des structures d'endettement réelles des entreprises ayant des dettes multi-échéances, des lignes de crédit revolving, des clauses restrictives.

Pour pallier ces insuffisances, Black et Cox (1976) ont introduit les modèles structurels à barrière. Dans ces extensions, le défaut est déclenché dès que la valeur des actifs (V_t) franchit un certain seuil critique inférieur L_t considérée comme une « barrière de faillite », à n'importe quel moment du cycle de vie du contrat de crédit. La modélisation mathématique fait alors appel aux lois de premier passage du mouvement brownien, augmentant la fidélité des prédictions empiriques, mais élevant substantiellement la complexité computationnelle du système.

2.2 L'approche en forme réduite : Modèles à intensité et processus de saut

Face aux contraintes de l'approche structurelle à modéliser la dynamique interne de la firme, l'école de l'approche par intensité, initiée par Artzner et Delbaen (1992), Jarrow et Turnbull (1995), puis systématisée par Duffie et Singleton (1999) renonce à lier le défaut à la valeur des actifs. Le défaut y est traité comme un événement purement exogène modélisé par le temps d'arrêt d'un processus de saut de Poisson.

Soit T l'instant aléatoire de défaut. Le taux de hasard instantané, ou intensité stochastique λ_t , représente la probabilité conditionnelle de défaut sur un intervalle infinitésimal $[t, t+dt]$, sachant que l'emprunteur a survécu jusqu'à t :

$$P(t \leq \tau \leq t + dt \mid \tau > t) = \lambda_t * dt$$

Par intégration de cette relation stochastique, la fonction de survie s'est à dire la probabilité que la contrepartie ne fasse pas défaut avant l'horizon temporel T s'exprime sous la forme :

$$P(\tau > T \mid F_t) = \exp\left(-\int_t^T \lambda_s ds\right)$$

Par conséquent, la Probabilité de Défaut (PD) cumulative sur l'intervalle $[t, T]$ s'écrit:

$$PD(t, T) = 1 - \exp\left(-\int_t^T \lambda_s ds\right)$$

Dans les modélisations avancées, l'intensité λ_t n'est pas constante mais elle est elle-même modélisée comme un processus stochastique positif (processus de Cox) et peut être spécifiée comme une fonction affine de facteurs macroéconomiques et microéconomiques X_t :

$$\lambda_t = \alpha_0 + \beta^t X_t$$

Où X_t intègre des facteurs de risque exogènes tels que la volatilité des taux directeurs, l'évolution du PIB, l'indice d'endettement du secteur d'activité, ou des ratios de liquidité spécifiques à l'entreprise.

L'avantage des modèles en forme réduite réside dans leur flexibilité mathématique complète pour la tarification des instruments financiers de crédit tels que les obligations risquées, les produits dérivés. Le calcul des espérances mathématiques sous la mesure risque-neutre s'apparente à des calculs de structures de taux d'intérêt standard, similaires aux modèles de taux de type Cox-Ingersoll-Ross. Néanmoins, ces modèles souffrent d'un déficit explicatif majeur : le défaut est déconnecté des décisions de gestion et de la santé financière intrinsèque de l'entreprise, pour devenir un simple saut statistique exogène et abstrait.

2.3 L'approche statistique traditionnelle : La régression logistique et le Credit Scoring

Si les modèles de Merton et de Jarrow-Turnbull dominent la littérature de la finance de marché, la gestion du risque bancaire quotidien de détail (crédits à la consommation, prêts immobiliers, financements de proximité des PME) repose principalement sur des approches empirico-statistiques, au premier rang desquelles figure la Régression Logistique (modèle Logit).

Le cadre conceptuel du « crédit scoring » consiste à modéliser la variable binaire dépendante Y_i , qui prend la valeur 1 si l'emprunteur i fait défaut au cours d'un horizon temporel fixé et 0 sinon. On cherche à estimer la probabilité conditionnelle de défaut $p_i = P(Y_i = 1 | X_i)$ étant donné un vecteur $X_i = (x_{i1}, x_{i2}, \dots, x_{ik})^T$ qui réunit les caractéristiques de l'emprunteur (ratios financiers, âge, historique de compte, statut d'emploi, etc.).

Pour contraindre la probabilité estimée dans l'intervalle $[0, 1]$, le modèle applique la fonction Logit sur le ratio des chances :

$$\ln\left(\frac{p_i}{1-p_i}\right) = \beta_0 + \sum_{j=1}^k \beta_j x_{ij}$$

Par inversion de la fonction Logit, la probabilité de défaut s'exprime via la fonction sigmoïde cumulative :

$$p_i = \frac{1}{1 + e^{-(\beta_0 + \sum_{j=1}^K \beta_j x_{ij})}}$$

L'estimation des paramètres β s'effectue par la méthode du Maximum de Vraisemblance, en maximisant la fonction de log-vraisemblance suivante sur un échantillon d'apprentissage de taille N :

$$\text{Log} - L(\beta) = \sum_{i=1}^N [y_i \ln(p_i) + (1 - y_i) \ln(1 - p_i)]$$

Les coefficients retenus permettent d'établir des grilles de score (Scorecard) attribuant des points par modalité. Ce dispositif offre une transparence et une interprétabilité directes pour l'analyse de crédit.

Cependant, l'analyse Logit traditionnelle montre de sévères limites face aux structures de données contemporaines : - **Hypothèse de Linéarité**: Le modèle postule que la relation entre le log-odds et les variables explicatives est strictement linéaire. Or, en finance, les relations sont fréquemment non linéaires (cas d'un ratio de levier sain, mais son impact négatif s'accélère de façon exponentielle au-delà d'un certain seuil critique). - **Sensibilité aux données manquantes et aberrantes** : La régression logistique requiert un nettoyage minutieux et est fortement perturbée par les valeurs extrêmes ou les données manquantes, fréquentes dans les bases de données bancaires non structurées. - **Incapacité à gérer la multicollinéarité** : Si deux variables explicatives sont fortement corrélées (comme le ratio de rentabilité des actifs et le ratio de rentabilité des capitaux propres), les variances des estimateurs explosent, rendant le modèle instable et peu fiable pour l'analyse des coefficients.

3 Rupture épistémologique : Le paradigme du Machine Learning

3.1 Fondements algorithmiques des méthodes d'apprentissage supervisé avancées

Le passage au Machine Learning modifie fondamentalement la philosophie de modélisation. Au lieu de postuler une relation fonctionnelle prédéfinie à l'avance entre les variables d'entrée et le risque de défaut, l'approche algorithmique laisse la machine découvrir par itérations successives les structures d'interaction, les non-linéarités complexes et les segmentations optimales au sein des données.

3.1.1 Random Forest (Forêts Aléatoires) : L'approche par agrégation de décisions

Développé par Leo Breiman (2001), le modèle des Forêts Aléatoires est un algorithme d'apprentissage d'ensemble (Ensemble Learning) fondé sur la combinaison d'un grand nombre d'arbres de décision individuels de type CART (Classification and Regression Trees). L'objectif sous-jacent est de réduire drastiquement la variance d'un arbre de décision unique (qui tend à fortement mémoriser le bruit et à sur-apprendre) sans en augmenter le biais.

L'architecture repose sur deux principes fondamentaux de diversification stochastique : 1. **Le Bagging (Bootstrap Aggregating)** : Pour construire chaque arbre de la forêt, un sous-échantillon d'apprentissage distinct est généré par un tirage aléatoire avec remise (bootstrap) à partir de la base de données initiale. Si la base contient N observations, chaque échantillon bootstrap possède également une taille N , mais contient environ 63,2 % d'observations uniques, le reste étant des doublons. Les observations non sélectionnées forment l'échantillon *Out-Of-Bag* (OOB), utilisé pour évaluer la performance du modèle sans recourir à un échantillon de validation externe. 2. **Le sous-tirage de variables (Feature Frustration)** : Lors du fractionnement de chaque nœud au sein d'un arbre, l'algorithme ne cherche pas le meilleur séparateur parmi l'intégralité des K variables disponibles. Il sélectionne au préalable un sous-ensemble aléatoire de taille $m = \sqrt{K}$ variables et détermine la coupure optimale uniquement sur ce sous-ensemble. Cette corrélation minimale entre les arbres garantit la robustesse collective de la forêt.

La probabilité finale de défaut estimée pour un profil d'emprunteur donné correspond à la moyenne arithmétique simple des probabilités empiriques prédites par l'ensemble des M arbres de la forêt :

$$P_{final}(Y = 1 | X) = \frac{1}{M} \sum_{m=1}^M \mathbb{P}_{arbre_m}(Y = 1 | X)$$

3.1.2 Gradient Boosting (XGBoost et LightGBM) : l'apprentissage séquentiel par correction des erreurs

Contrairement au Random Forest où les arbres croissent en parallèle de manière indépendante, le Gradient Boosting s'inscrit dans une logique séquentielle et cumulative. Les arbres de décision, généralement peu profonds, sont construits les uns après les autres, chaque nouvel arbre ayant pour mission explicite de modéliser et de corriger les erreurs résiduelles commises par la combinaison des arbres précédents.

Formellement, pour une fonction de perte différentiable $L(y, \hat{y})$ comme la perte logistique pour un

problème de classification binaire du défaut, l'algorithme cherche à optimiser de manière itérative un modèle additif :

$$F_m(X) = F_{m-1}(X) + \gamma_m h_m(x)$$

Où $h_m(X)$ représente le nouvel arbre entraîné à l'étape m , et γ_m correspond au pas d'apprentissage (learning rate). Pour orienter la construction de $h_m(X)$, l'algorithme calcule à chaque itération les pseudo-résidus, qui correspondent à l'opposé du gradient de la fonction de perte par rapport aux prédictions actuelles du modèle :

$$r_{im} = - [\partial L(y_i, F_{m-1}(x_i)) / \partial F_{m-1}(x_i)]$$

L'algorithme XGBoost, introduit par Chen et Guestrin (2016), a optimisé ce processus en intégrant un développement de Taylor du second ordre de la fonction de perte pour accélérer la convergence, couplé à un terme de régularisation stricte (L1 et L2) dans la fonction objectif pour pénaliser la complexité des arbres et empêcher le sur-apprentissage :

$$Obj_m = \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + h_m(x_i)) + \Omega(h_m)$$

Avec $\Omega(h) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$ où T représente le nombre de feuilles de l'arbre et w_j les scores des feuilles. XGBoost et LightGBM, qui développent les arbres selon une stratégie de croissance par feuille plutôt que par niveau, s'avèrent être les algorithmes les plus performants du marché pour traiter les bases de données financières tabulaires complexes.

3.1.3 Réseaux de neurones artificiels et Deep Learning

Inspirés des structures neurobiologiques, les réseaux de neurones multicouches (Perceptron Multicouche - MLP) projettent les variables explicatives d'entrée à travers une série de couches cachées composées de nœuds interconnectés (neurones). Chaque neurone applique une combinaison linéaire des valeurs de la couche précédente, pondérée par des poids synaptiques W , augmentée d'un biais b , puis fait passer le résultat dans une fonction d'activation non linéaire :

$$a_j = f(\sum_i (w_{ij} x_i) + b_j)$$

L'apprentissage s'effectue via l'algorithme de rétropropagation du gradient (Backpropagation). Les erreurs de prédiction de défaut à la couche de sortie sont converties en une perte globale, puis répercutées en arrière à travers le réseau à l'aide de la règle de dérivation en chaîne afin de mettre à jour de façon itérative l'ensemble des matrices de poids par descente de gradient.

3.2 De la prédiction métrique à l'estimation prudentielle des paramètres du risque

L'application du Machine Learning à la sphère réglementaire des institutions financières exige d'aller au-delà de la simple classification binaire (Défaut / Non-Défaut) pour structurer l'estimation quantitative des trois paramètres pivots de la formule des exigences de fonds propres selon l'approche IRB de Bâle III.

3.2.1 Probabilité de Défaut (PD)

Pour la PD, les scores bruts générés par des algorithmes comme XGBoost ou les réseaux de neurones ne constituent pas directement des probabilités calibrées. Ils représentent des indices de séparabilité relative. Pour être exploitables suivant le cadre prudentiel, ces scores doivent subir une phase de calibration de la PD, consistant à cartographier les scores bruts vers les taux de défaut réels observés historiquement à long terme.

On utilise pour ce faire des techniques de régression isotone ou l'ajustement de Platt (1999), garantissant que si le modèle annonce une PD de 2 %, environ 2 dossiers sur 100 au sein de cette classe de risques feront effectivement défaut sur un an.

3.2.2 Perte en cas de défaut (LGD - Loss Given Default)

La LGD représente le pourcentage de l'exposition financière qui sera définitivement perdu par la banque si le défaut survient, après épuisement des procédures de recouvrement et de liquidation des garanties. La LGD est une variable continue confinée dans l'intervalle $[0, 1]$. Sa distribution empirique présente une forme fortement bimodale : une forte concentration d'observations autour de 0 (recouvrement intégral grâce aux garanties) et autour de 1 (perte totale sans recours possible).

Les modèles de régression linéaire classiques échouent à modéliser cette bimodalité, prédisant fréquemment des valeurs aberrantes en dehors des bornes réelles. Le Machine Learning résout cette impasse par des approches hybrides. Un premier modèle de classification (par exemple, un Random Forest) estime la probabilité que la perte soit totale ou nulle. Ensuite, un modèle de régression avancé, à travers un algorithme de boosting de gradient optimisé avec une fonction de perte de type bêta-déviance, estime le taux de perte exact pour les dossiers situés dans la zone intermédiaire. Cette articulation améliore significativement la précision d'estimation de la LGD par rapport aux techniques Tobit traditionnelles.

3.2.3 Exposition Au moment du Défaut (EAD - Exposure at Default)

L'EAD mesure le montant total des engagements dus par l'emprunteur à l'instant précis où le défaut se matérialise. Pour des lignes de crédit à terme fixe, l'EAD est connue avec certitude. En revanche, pour des lignes de crédit confirmées non tirées (crédits revolving, découverts autorisés, facilités de caisse), l'EAD dépend du comportement de l'emprunteur, qui tend à tirer massivement sur ses lignes de crédit disponibles à mesure qu'il s'enfonce dans l'illiquidité.

Traditionnellement, les banques appliquent des Facteurs de Conversion de Crédit (CCF) forfaitaires et fixes par type de produit. Le Machine Learning permet de modéliser dynamiquement le CCF en transformant ce paramètre en une fonction de variables comportementales de haute fréquence : fréquence des dépassements de ligne, vitesse de variation des soldes de comptes courants, modifications des profils de virements commerciaux. Les modèles de Boosting ou de réseaux de neurones récurrents appliqués aux séries temporelles de données transactionnelles permettent d'anticiper les variations d'EAD plusieurs mois avant la déclaration formelle du défaut.

3.3 Analyse comparative des performances prédictives (AUC, Gini)

Pour valider scientifiquement la supériorité d'une méthodologie de quantification sur une autre, la pratique financière utilise des indicateurs de discrimination standardisés, indépendants du choix du seuil de coupure commercial.

Le principal outil est la courbe ROC (Receiver Operating Characteristic), qui trace le Taux de Vrais Positifs (sensibilité) en fonction du Taux de Faux Positifs (1 - spécificité) pour l'intégralité des seuils possibles. L'Aire sous la Courbe ROC (AUC - Area Under the Curve) synthétise cette performance en une valeur unique comprise entre 0,5 (pouvoir discriminant équivalent à un tirage à pile ou face aléatoire) et 1,0 (séparation parfaite et sans erreur entre sains et défectueux).

Un indicateur dérivé est le coefficient de Gini (ou indice de précision), lié à l'AUC par la relation linéaire : $Gini = 2 AUC - 1$

Le tableau d'évaluation synthétique ci-dessous récapitule les performances relatives, les caractéristiques d'exploitation et les exigences structurelles des différentes classes de modèles analysées :

Modèle / Conception	Régression Logistique (Logit)	Modèles Structurels (Merton / Barrière)	Random Forest (Forêts Aléatoires)	Gradient Boosting (XGBoost / LightGBM)	Deep Learning (Réseaux Multicouches)
AUC Moyen	0,68 - 0,75	0,62 - 0,70	0,78 - 0,84	0,82 - 0,89	0,80 - 0,88
Complexité	Très faible	Modérée / Calcul stochastique	Élevée	Élevée	Très élevée GPU requis
Interprétabilité	Totale Coefficients linéaires	Économique Distance au défaut	Partielle Importance des variables	Faible Nécessite des outils XAI	Nulle Structure « Boîte Noire »
Principaux points forts	Simplicité à appliquer / conformité réglementaire / simple à auditer.	Fondement théorique solide/ relie le risque aux mécanismes de marché et de structure financière	Excellente réduction de la variance/ robuste aux données manquantes et aux valeurs aberrantes	Performance prédictive maximale sur données tabulaires/ gestion native des classes fortement déséquilibrées	Capacité d'extraction autonome de caractéristiques complexes à partir de données hétérogènes
Principales Faiblesses	Incapable de capter les non-linéarités intrinsèques et les interactions	Inexploitable pour les entreprises non cotées/ forte sensibilité aux hypothèses de volatilité	Lourd en mémoire vive/ difficile à extrapoler	Sensible au sur-apprentissage	Nécessite des volumes massifs de données pour converger

Source : Consolidé par le chercheur

3.4 Le dilemme de la boîte noire et la révolution de l'IA Explicable

Bien que la supériorité métrique des algorithmes d'apprentissage profond et d'ensembles d'arbres

de décision soit largement établie, leur déploiement opérationnel dans le secteur bancaire s'est heurté à un impératif réglementaire strict. Les organes d'audit interne, les commissaires aux comptes et les autorités de supervision bancaire imposent des exigences d'explicabilité fondamentales : Une institution financière ne peut juridiquement refuser un octroi de crédit à un particulier ou à une entreprise sur la base d'une prédiction opaque ou décision de boîte noire. Sur le plan opérationnel, cette opacité décisionnelle expose les institutions à des risques importants liés notamment l'amplification de biais discriminatoires involontaires, la méconnaissance d'effets procycliques masqués, ou encore une vulnérabilité accrue aux anomalies de données.

Afin de surmonter cet arbitrage critique entre performance prédictive et transparence réglementaire, la littérature récente s'est emparée des méthodes d'Intelligence Artificielle Explicable (XAI). Ces dispositifs d'explicabilité post-hoc permettent de rouvrir la « boîte noire » algorithmique sans dégrader sa précision. Deux approches prédominent aujourd'hui dans la modélisation du risque de crédit :

3.4.1 Les valeurs de Shapley (SHAP - Shapley Additive explanations)

Issue de la théorie des jeux coopératifs (Shapley, 1953), l'approche SHAP (Lundberg & Lee, 2017) conceptualise chaque variable explicative comme un « joueur » au sein d'une coalition, et la prédiction du modèle pour un emprunteur spécifique comme le « gain » total de la partie. La valeur SHAP attribuée à une variable correspond à sa contribution marginale moyenne à la prédiction, calculée sur l'intégralité des sous-ensembles ou coalitions possibles de variables d'entrée. La formulation mathématique de la valeur SHAP $\Phi_i(x)$ de la caractéristique i s'écrit:

$$\Phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_x(S \cup \{i\}) - f_x(S)]$$

Où F est l'ensemble total des variables, S est un sous-ensemble de variables ne contenant pas i , et $f_x(S)$ représente la prédiction du modèle conditionnelle aux variables contenues dans S .

Grâce à leurs propriétés théoriques d'additivité locale et de cohérence, les valeurs SHAP permettent une décomposition exacte de l'écart entre la prédiction individuelle et la prédiction moyenne du portefeuille. Si un modèle de boosting annonce une PD de 12 % pour une entreprise alors que la moyenne du portefeuille est de 3 %, l'analyse SHAP permet d'isoler mathématiquement que +5 % sont imputables à la dégradation de son ratio de liquidité générale et +4 % à l'augmentation de son encours de dette de court terme, rendant le modèle parfaitement transparent pour le décideur.

3.4.2 LIME (Local Interpretable Model-agnostic Explanations)

Proposée par Ribeiro et al. (2016), la méthode LIME repose sur un principe d'approximation locale. Bien que la surface de décision globale d'un algorithme de Machine Learning soit hautement non linéaire et indéchiffrable à l'échelle du portefeuille complet, elle peut être approchée de manière linéaire au voisinage immédiat d'une observation spécifique x pour un emprunteur donné).

Pour expliquer une prédiction locale, LIME génère une série de perturbations aléatoires autour des

caractéristiques de l'emprunteur ciblé, observe les prédictions générées par la « boîte noire » pour ces profils fictifs, et pondère ces observations en fonction de leur proximité avec l'individu réel. Ensuite, LIME entraîne un modèle explicable par nature (comme une simple régression linéaire) sur ce jeu de données localement perturbé. Les coefficients de cette régression locale servent d'explications directes et immédiates pour expliciter le diagnostic de risques à cet instant précis.

4 Étude empirique : comparaison des paradigmes sur un échantillon d'entreprises

4.1 Objectif et positionnement

L'étude empirique a pour objectif de confronter les enseignements théoriques à la réalité du tissu économique algérien en vérifiant la performance des modèles de quantification du risque de crédit sur un portefeuille de PME ayant introduit une demande de financement auprès d'une banque publique à réseau dense et ce afin de quantifier le gain de pouvoir discriminant apporté par les algorithmes de Machine Learning par rapport à la régression logistique, d'identifier à travers les outils d'explicabilité (SHAP) les principaux paramètres du défaut dans un contexte caractérisé par l'importance des garanties réelles et l'asymétrie d'information.

4.2 Données et échantillon

L'échantillon comprend 800 entreprises. Le taux de défaut observé s'élève à 29,2 % (mesuré à travers des incidents de paiement sur période de 12 à 36 mois). Les variables explicatives couvrent les dimensions classiques de l'analyse financière (structure d'endettement, liquidité, rentabilité, solvabilité, taille) ainsi que des éléments spécifiques au contexte algérien (ratio de couverture par les garanties, type de sûreté, historique d'impayés). Un nettoyage préalable a été effectué (imputation par la médiane, traitement des valeurs extrêmes).

4.3 Modèles estimés et critères d'évaluation

Quatre paradigmes ont été estimés : (1) Régression logistique (avec pondération des classes) ; (2) Random Forest ; (3) XGBoost ; (4) Réseau de neurones multicouche (MLP). Les métriques retenues sont l'AUC-ROC, le coefficient de Gini, l'Accuracy et le Brier Score (qualité de calibration). L'explicabilité a été analysée à travers l'importance des variables (XGBoost) et les valeurs SHAP.

4.4 Principaux résultats

Le tableau suivant synthétise les performances sur l'échantillon de test :

Modèle	AUC	Gini	Accuracy	Brier
Régression logistique	0,79	0,58	0,69	0,189
Random Forest	0,86	0,72	0,85	0,153
XGBoost	0,87	0,74	0,83	0,134
Réseau de neurones (MLP)	0,74	0,48	0,71	0,196


Source : Consolidé par le chercheur

Les résultats confirment la supériorité discriminante des algorithmes de boosting (XGBoost, AUC=0,87) et, dans une moindre mesure, des forêts aléatoires (AUC = 0,86) par rapport à la régression logistique (AUC = 0,79) qui conserve néanmoins un niveau de discrimination acceptable

et reste pertinente comme modèle de référence interprétable.

Le réseau de neurones est classé en dernière position avec le AUC le plus faible. Le score Brier indique une calibration suffisante des algorithmes de Boosting.


Figure 1 – Courbes ROC des quatre modèles



Source : élaboré par le chercheur

Le graphique ci-après met en évidence les variables qui contribuent le plus à la discrimination du défaut :


Figure 2 – Importance des variables (XGBoost – Top 12)



Source : élaboré par le chercheur

L'analyse SHAP permet de décomposer la contribution de chaque variable à la prédiction individuelle de défaut. Chaque point représente une entreprise, la couleur indique la valeur de la variable et la position horizontale mesure l'impact sur le score de risque tel qu'indiqué dans la figure ci-après :

Figure 3 – SHAP Summary Plot (explicabilité globale)



Source : élaboré par le chercheur

5 Le système bancaire algérien face aux défis de modernisation quantitative

5.1 Caractéristiques du secteur bancaire national

Pour appréhender la pertinence et les modalités d'une modernisation des outils de quantification du risque de crédit en Algérie, il convient d'analyser au préalable les spécificités structurelles de son écosystème bancaire. Le paysage financier algérien se caractérise par une forte concentration et une prédominance de l'intermédiation classique. Le secteur est structurellement dominé par six banques publiques commerciales (BNA, BEA, CPA, BADR, BDL et CNEP-Banque), qui concentrent à elles seules plus de 85 % des actifs totaux, des dépôts et des encours de crédit à l'économie. Le reliquat du marché est partagé par une douzaine de filiales de banques internationales privées (principalement européennes et moyen-orientales), dont l'activité s'oriente prioritairement vers le financement du commerce extérieur et des grandes entreprises privées.

Cette prépondérance étatique confère au système bancaire un rôle central d'instrument de politique économique et de soutien au secteur public financier et industriel. De cette structuration découlent trois caractéristiques managériales et institutionnelles majeures : - **Une culture du risque centrée sur les garanties** : L'octroi de crédits au sein des banques publiques algériennes demeure historiquement adossé à l'exigence de sûretés réelles lourdes (hypothèques immobilières,

nantissements de fonds de commerce, garanties de l'Etat) plutôt qu'à une évaluation purement prédictive de la rentabilité intrinsèque et des flux de trésorerie futurs de l'emprunteur. Cette pratique s'explique en partie par la volonté des décideurs de se prémunir contre le risque de mise en cause juridique et administrative en cas de défaut de la contrepartie. - **Un marché financier embryonnaire** : La Bourse d'Alger présente un nombre très restreint de titres cotés et une capitalisation globale marginale au regard du Produit Intérieur Brut (PIB). L'absence d'un marché obligataire d'entreprises profond et liquide prive les institutions financières de signaux de prix de marché (tels que les spreads de crédits ou les cotations d'actions). Cette contrainte rend de facto inapplicables les modèles structurels à la Merton ou les approches basées sur des dérivées de crédit (CDS) pour évaluer le tissu économique local. - **Une asymétrie d'information prononcée** : Le tissu économique national est majoritairement composé de Petites et Moyennes Entreprises (PME) et d'entreprises familiales caractérisées par une transparence financière limitée (états financiers parfois non audités, recours important au comptant, sous-capitalisation). Cette asymétrie d'information prononcée complexifie le calibrage des ratios financiers et exige des modèles de scoring adaptés aux données disponibles.

5.2 État des lieux du cadre réglementaire et de supervision prudentielle

La Banque d'Algérie, en sa qualité d'autorité monétaire et de régulateur prudentiel, pilote la modernisation du secteur à travers la promulgation des règlements du Conseil de la Monnaie et du Crédit. La trajectoire d'adoption des standards prudentiels de Bâle au sein de l'écosystème national s'inscrit dans une logique de prudence progressive visant à préserver la stabilité financière globale.

À ce jour, la quasi-totalité des établissements de crédit de la place algérienne applique de manière exclusive l'Approche Standard pour la détermination de l'exigence de fonds propres au titre du risque de crédit. Sous ce régime, les actifs pondérés par le risque (Risk-Weighted Assets - RWA) sont calculés en appliquant aux encours bruts des coefficients de pondération forfaitaires et rigides définis par la réglementation (ex. 0% pour les créances sur l'État, 100% pour les entreprises privées, 75% pour le portefeuille de clientèle de détail), ajustés uniquement par la prise en compte de sûretés et garanties éligibles.

Bien que la transition vers les approches basées sur les notations internes (IRB - Internal Ratings-Based), permettant d'utiliser des estimations propres de la Probabilité de Défaut (PD) et de la Perte en Cas de Défaut (LGD), constitue un objectif stratégique à moyen terme, sa mise en œuvre effective se heurte à deux verrous majeurs :

- **L'exigence réglementaire de séries historiques longues** : Les standards internationaux et les exigences de supervision requièrent un historique de données homogènes d'au moins 5 à 7 ans d'observations continues sur les défauts pour valider et calibrer un modèle de notation interne. Or, au sein de plusieurs banques de la place, la discontinuité des systèmes d'information, les évolutions du plan comptable et les restructurations récurrentes de créances ont altéré la qualité et la traçabilité de ces bases de données historiques.

- **Le défi du provisionnement réglementaire** : Le secteur bancaire évolue à la croisée de deux logiques de provisionnement. D'une part, les règles prudentielles de la Banque d'Algérie qui imposent des règles de classification des créances et des taux de provisionnement minimaux par catégories (courantes, à problèmes potentiels (C1), très risquées (C2) et compromises (C3)).

D'autre part, pour les banques étrangères qui s'alignent sur les normes comptables internationales ou des variantes de reporting avancées, l'intégration des concepts de pertes de crédit attendues, introduits par la norme IFRS 9, exige des modélisations prospectives intégrant des scénarios macroéconomiques, ce qui accentue la nécessité de développer des outils prédictifs quantitatifs plus sophistiqués que la simple approche statutaire.

5.3 Obstacles structurels à l'adoption du Machine Learning en Algérie

L'introduction des technologies d'apprentissage supervisé avancées (Machine Learning) au sein des banques algériennes se heurte à un triptyque d'obstacles interconnectés, combinant des dimensions technologiques, culturelles et de gouvernance.

5.3.1 Limites technologiques et gouvernance des données

Les modèles de Machine Learning sont par essence des consommateurs intensifs de données de haute qualité. Pour qu'un algorithme comme XGBoost surpasse une régression logistique, il doit être alimenté par des données volumineuses, nettoyées, standardisées et exemptes de biais systématiques. Or, l'architecture des systèmes d'information des banques algériennes, bien qu'en cours de modernisation accélérée à travers le déploiement de nouveaux progiciels de Core Banking, souffre encore de cloisonnements structurels et des silos d'information.

Les données relatives aux caractéristiques des emprunteurs, à l'historique des incidents de paiement, aux mouvements des comptes courants et à l'évaluation des garanties sont fréquemment stockées dans des bases décentralisées, compliquant leur réconciliation. De plus, les données non structurées tels que les rapports des analystes financiers ou les procès-verbaux des comités de crédit, reste sous-exploité faute de déploiement de techniques de traitement automatique du langage naturel.

5.3.2 Faiblesse des infrastructures de centralisation de l'information financière

À l'échelle macro-institutionnelle, l'absence d'agences de notation privées nationales qui collectent et consolident les historiques de paiement des particuliers et des entreprises pour le compte de l'ensemble de la place limite la profondeur des analyses.

Bien que la Banque d'Algérie gère une Centrale des Risques et une Centrale des Impayés pour recenser les grands engagements, la granularité des informations partagées reste orientée vers le contrôle réglementaire global plutôt que vers l'alimentation directe de modèles prédictifs micro-analytiques.

5.3.3 Le Déficit de capital humain spécialisé

La conception, le calibrage, la validation, le déploiement et le suivi continu de modèles de Machine Learning requièrent une double expertise : une maîtrise approfondie des algorithmes mathématiques et une compréhension fine des mécanismes financiers et prudentiels bancaires.

La rareté des profils hybrides de Data Scientists financiers conjuguée à la forte tension sur le marché international du travail crée une fuite des talents technologiques. Cette situation nuit à la capacité des banques nationales à attirer et retenir les compétences requises pour la maintenance de leurs outils de modélisation interne.

6 Recommandations stratégiques pour une transition durable

Afin de surmonter les verrous structurels identifiés et permettre au secteur bancaire algérien de réussir la modernisation de son architecture de scoring, nous préconisons une feuille de route articulée autour de quatre piliers stratégiques.

6.1 Refonte architecturale des SI et implémentation des lacs de données

Les institutions bancaires nationales doivent abandonner l'architecture en silos de leurs systèmes d'information en érigeant des lacs de données centralisés. Ces infrastructures ont vocation à ingérer et traiter des flux hétérogènes de données structurées telles que les données comptables, historiques de crédit, les données transactionnelles à haute fréquence, etc. et non structurées comme les comportements digitaux, les caractéristiques juridiques des garanties, etc.

Cette mutualisation technique doit impérativement s'adosser à un cadre rigoureux de gouvernance des données, garantissant l'automatisation du nettoyage, la gestion des valeurs manquantes et la traçabilité. L'intégrité de la donnée constitue le prérequis absolu à l'entraînement d'algorithmes robustes, conformément au principe fondamental de la science des données : Données erronées en entrée, résultats erronés en sortie.

6.2 Modernisation de la supervision

La transition technologique requiert un accompagnement proactif de l'autorité de supervision. La mise en place, par la Banque d'Algérie, d'un « bac à sable réglementaire », à l'instar des initiatives des banques centrales internationales permettra aux banques d'expérimenter des modèles de Machine Learning notamment sur les segments des PME et du micro-crédit, dans un environnement pilote sécurisé, en parallèle de l'approche standard officielle.

Cette phase d'apprentissage conjoint permettra à la Banque d'Algérie de coconstruire les directives d'audit des algorithmes complexes tout en mesurant leur impact sur la stabilité des ratios de solvabilité (RWA) avant leur homologation officielle.

6.3 Alliance stratégique universités-banques et valorisation du Capital Humain

Pour combler le déficit de compétences quantitatives, les institutions financières doivent nouer des partenariats stratégiques institutionnels avec les universités et des écoles supérieures.

Ces alliances doivent se matérialiser par la création de Masters spécialisés en « Ingénierie

Financière et Data Science », le cofinancement de projets de recherche appliquée, et la mise en place de programmes de stages immersifs de longue durée au sein des institutions financières. Parallèlement, les banques doivent offrir des plans de carrière stimulants pour les profils technologiques afin de freiner la fuite des talents.

6.4 L'adoption de l'IA explicable comme standard opérationnel

Afin de concilier la performance prédictive et les obligations déontologiques et réglementaires de transparence, les banques algériennes ne doivent pas déployer de modèles de Machine Learning de type «boîte noire» à l'état brut. L'intégration native des frameworks d'IA Explicable (SHAP et LIME) doit être érigée en standard technologique obligatoire au sein de toutes les architectures analytiques de risques.

Tout score de crédit généré par une forêt aléatoire ou un modèle de boosting doit être systématiquement accompagné de sa feuille de décomposition SHAP traduite en indicateurs métriques compréhensibles par les analystes de crédit, cette décomposition permettra d'une part de justifier de manière transparente les décisions d'octroi ou de rejet auprès des clients, et d'autre part de fournir aux contrôleurs externes les preuves mathématiques de la rationalité économique des modèles.

7 Conclusion

La modélisation et la quantification du risque de crédit connaissent une mutation majeure dans l'histoire des sciences financières. La trajectoire d'évolution théorique met en lumière une transition progressive : des structures axiomatiques de la finance classique, qui ont posé les fondements théoriques indispensables de la distance au défaut et des taux de hasard, vers le pragmatisme empirique et la puissance computationnelle du Machine Learning. Loin d'invalidier les apports théoriques de Merton ou de Jarrow-Turnbull, l'avènement de l'intelligence artificielle les prolonge et les enrichit en offrant des outils capables d'absorber la non-linéarité, l'hétérogénéité et la complexité intrinsèque des données financières contemporaines.

Pour le secteur bancaire algérien, cette dynamique scientifique internationale ne doit pas être appréhendée comme une contrainte prématurée ou un luxe technologique réservé aux marchés développés hyper-financiarisés. Elle représente au contraire une opportunité stratégique unique : un accélérateur de convergence. En investissant massivement dans la gouvernance de ses données, en s'appropriant les méthodologies de l'IA explicable et en collaborant étroitement avec les établissements académiques, la banque peut opérer un saut qualitatif déterminant.

La modernisation de sa gestion des risques renforcera sa résilience face aux chocs macroéconomiques potentiels, préservera la confiance des déposants et optimisera l'allocation des capitaux vers les secteurs productifs, s'affirmant ainsi comme pivot financier incontournable pour la diversification de l'économie nationale.

3. Liste Bibliographique: (APA)

- Artzner, P., & Delbaen, F. (1992). Credit risk and prepayment option. *Astin Bulletin*, 22(1), 81–96.
- Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81(3), 637-654.
- Black, F., & Cox, J. C. (1976). Valuing corporate securities: Some effects of bond indenture provisions. *The Journal of Finance*, 31(2), 351-367.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Duffie, D., & Singleton, K. J. (1999). Modeling term structures of defaultable bonds. *The Review of Financial Studies*, 12(4), 687-720.
- International Accounting Standards Board, 2014, IFRS 9 Financial Instruments.
- Jarrow, R. A., & Turnbull, S. M. (1995). Pricing derivatives on financial securities subject to credit risk. *The Journal of Finance*, 50(1), 53-85.
- Longstaff, F. A., & Schwartz, E. S. (1995). A simple approach to valuing risky fixed and floating rate debt. *The Journal of Finance*, 50(3), 789-819.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems (NeurIPS)*, 4765-4774.
- Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of Finance*, 29(2), 449-470.
- Platt, J. C. (1999). Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In *Advances in Large Margin Classifiers* (pp. 61–74). MIT Press.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?": Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135-1144.