

Machine Learning et audit interne intelligent : une approche orientée décision pour la détection des anomalies financières et la réduction du risque de fraude chez les entreprises marocaines

Machine Learning and Intelligent Internal Audit: A Decision-Oriented Approach to Financial Anomaly Detection and Fraud Risk Reduction in Moroccan companies.

Auteur 1 : BRAHMI Mostafa,

BRAHMI Mostafa, (ORCID : 0009-0007-8065-1274)

Docteur en Sciences Économiques et Gestion,

Faculté des sciences juridiques économiques et sociales

Université Mohammed Premier-Oujda-Maroc

Laboratoire interdisciplinaire de recherches économiques, économétriques et managériales - LIREEM

Déclaration de divulgation : L'auteur n'a pas connaissance de quelconque financement qui pourrait affecter l'objectivité de cette étude.

Conflit d'intérêts : L'auteur ne signale aucun conflit d'intérêts.

Pour citer cet article : BRAHMI Mostafa (2026) « Machine Learning et audit interne intelligent : une approche orientée décision pour la détection des anomalies financières et la réduction du risque de fraude chez les entreprises marocaines », African Scientific Journal « Volume 03, Num 37 » pp: 001 – 029.



DOI : 10.5281/zenodo.22716067

Copyright © 2026 – ASJ



Résumé

La transformation digitale des organisations a profondément modifié l'environnement informationnel de l'audit interne. L'augmentation du volume, de la granularité et de l'interconnexion des données financières met sous tension les approches traditionnelles fondées sur l'échantillonnage et les contrôles a posteriori. Dans ce contexte, cette étude analyse la contribution du machine learning au développement d'un audit interne orienté vers l'analyse et la décision au sein des entreprises marocaines.

La recherche repose sur un dispositif quantitatif en deux phases. Une première étape identifie les entreprises disposant d'un ERP opérationnel et d'outils de machine learning. Une seconde étape teste un modèle de médiation séquentielle par PLS-SEM auprès de 32 entreprises technologiquement équipées.

Les résultats montrent que le machine learning n'agit pas directement sur la création de valeur. Son effet est indirect : l'amélioration de la détection des anomalies renforce la qualité du jugement des auditeurs, ce qui réduit le risque de fraude et accroît la valeur ajoutée perçue. Le modèle explique 31 % de la variance de cette création de valeur.

En articulant technologie, décision et gouvernance, l'étude éclaire les mécanismes par lesquels l'analytique avancée soutient la gestion du risque dans un contexte émergent.

Mots clés : Machine learning, anomalies financières, PLS-SEM, ERP, Audit interne.

Abstract

The digital transformation of organizations has profoundly reshaped the informational environment of internal auditing. The growing volume, granularity, and interconnectedness of financial data challenge traditional audit approaches based on sampling and ex post controls. In this context, this study examines the contribution of machine learning to the development of a decision-oriented and analytically driven internal audit function within Moroccan organizations.

The research follows a two-phase quantitative design. The first phase identifies companies equipped with operational ERP systems and machine learning tools. The second phase tests a sequential mediation model using PLS-SEM on a sample of 32 technologically equipped firms.

The findings indicate that machine learning does not directly generate value for internal audit. Its impact is indirect: enhanced anomaly detection improves auditors' decision quality, which in turn reduces fraud risk and increases the perceived value added of the internal audit function. The model explains 31% of the variance in value creation.

By integrating technological, decision-making, and governance perspectives, this study clarifies the mechanisms through

Keywords: Machine learning, Anomaly detection, PLS-SEM, Internal Auditing.

1. Introduction

La digitalisation transforme profondément la manière dont les organisations fonctionnent. Les systèmes comptables et financiers produisent aujourd'hui des volumes considérables de données. Les ERP se généralisent et les processus sont de plus en plus automatisés. Cette évolution ouvre de nouvelles possibilités d'analyse, mais elle rend aussi la gestion des risques plus complexe (Alles & Gray, 2016).

Dans cet environnement numérique, la fraude change de nature. Elle devient plus sophistiquée, plus diffuse et parfois difficile à repérer dans la masse des transactions. Les méthodes traditionnelles d'audit interne, fondées sur l'échantillonnage et les contrôles a posteriori, montrent alors leurs limites face à cette complexité (Bierstaker et al., 2014 ; Kokina & Davenport, 2017).

En parallèle, la fonction d'audit interne évolue. Elle ne se limite plus à vérifier la conformité. Elle est désormais attendue comme un acteur clé de la gouvernance, de la gestion des risques et de l'aide à la décision (Sarens & Christopher, 2010 ; Roussy & Brivot, 2016). Les conseils d'administration et les comités d'audit attendent des auditeurs internes une capacité à anticiper les risques, à alerter rapidement et à éclairer les décisions stratégiques. Cela suppose une meilleure exploitation des données et une approche plus proactive de l'audit.

C'est dans ce cadre que s'inscrit le sujet de cette recherche. L'étude porte sur l'apport du machine learning à l'audit interne intelligent, en particulier pour la détection des anomalies financières et la réduction du risque de fraude dans les entreprises marocaines. Le machine learning apparaît comme une opportunité importante, car il permet d'analyser l'ensemble des transactions, d'identifier des anomalies rares et de repérer des comportements inhabituels qui peuvent échapper aux contrôles classiques (Kogan et al., 2014 ; Appelbaum et al., 2017). Les travaux récents soulignent également son potentiel pour soutenir l'audit continu et la surveillance en temps réel (Issa et al., 2021 ; Sutton et al., 2023).

Cependant, la technologie ne suffit pas. La performance des algorithmes ne garantit pas, à elle seule, la création de valeur (Alles & Gray, 2016 ; Moll & Yigitbasioglu, 2019). Ce qui importe réellement, c'est la manière dont ces outils sont intégrés dans les processus décisionnels de l'audit

interne. L'IA n'a pas vocation à remplacer l'auditeur. Elle doit plutôt renforcer son jugement professionnel, l'aider à prioriser les risques et améliorer la qualité de ses décisions.

Malgré l'intérêt croissant pour l'audit analytique, deux limites persistent dans la littérature. D'abord, plusieurs travaux se concentrent sur la performance technique des modèles de détection, sans analyser suffisamment les mécanismes organisationnels qui transforment l'outil en valeur réelle pour l'audit interne (Appelbaum et al., 2017 ; Sutton et al., 2023). Ensuite, la majorité des recherches portent sur des économies développées. Les contextes émergents restent encore peu étudiés, alors qu'ils présentent des niveaux variables de maturité digitale, de gouvernance et de qualité des données (Alzeban & Gwilliam, 2014 ; Mihret et al., 2010).

Le Maroc constitue ainsi un terrain d'étude pertinent. Les entreprises marocaines modernisent progressivement leurs dispositifs de gouvernance et adoptent davantage les ERP. Toutefois, les écarts restent importants en matière de compétences analytiques et d'intégration de l'intelligence artificielle dans l'audit interne. Certaines organisations avancent rapidement, tandis que d'autres restent attachées à des pratiques plus classiques.

L'objectif de cette recherche est donc d'analyser dans quelle mesure le machine learning peut renforcer l'audit interne en améliorant la détection des anomalies financières, la qualité de la prise de décision et la réduction du risque de fraude. Plus précisément, il s'agit de comprendre comment cet outil peut créer de la valeur pour la fonction d'audit interne dans le contexte marocain.

Pour atteindre cet objectif, cette recherche adopte une approche quantitative en deux phases. Ce choix méthodologique se justifie par la nature du sujet. Avant de tester l'effet du machine learning, il est nécessaire d'identifier les entreprises qui disposent réellement des conditions technologiques minimales, notamment un ERP opérationnel et des outils d'IA appliqués à l'audit ou au contrôle. La première phase permet donc de dresser un état des lieux. La seconde phase permet de tester, à l'aide d'un modèle PLS-SEM, les relations entre l'adoption du machine learning, la détection des anomalies, la qualité de la décision, la réduction du risque de fraude et la valeur ajoutée de l'audit interne.

La recherche est structurée autour de plusieurs parties. La première présente le cadre théorique relatif à l'évolution de l'audit interne, à la fraude financière, au machine learning et à la prise de décision augmentée. La deuxième développe les hypothèses de recherche. La troisième expose la méthodologie adoptée. La quatrième présente les résultats empiriques. Enfin, la dernière partie discute les résultats, leurs implications théoriques et managériales, ainsi que les perspectives de recherche.

En combinant audit interne, gouvernance et intelligence artificielle, cette étude défend l'idée que la valeur du machine learning ne réside pas uniquement dans sa sophistication technique. Elle réside surtout dans sa capacité à soutenir le jugement de l'auditeur, à structurer la décision et à renforcer la gouvernance interne.

2. Revue de littérature et cadre théorique

2.1. L'évolution de l'audit interne :

Longtemps, l'audit était centré sur la conformité et la vérification des procédures, il occupe aujourd'hui une place plus stratégique dans les organisations. Il ne s'agit plus seulement de contrôler, il s'agit d'accompagner la gouvernance et de contribuer à la création de valeur.

Les travaux récents confirment cette évolution. L'audit interne est désormais perçu comme un acteur clé de la gestion des risques et de la performance organisationnelle (Roussy & Brivot, 2016 ; IIA, 2020). Les conseils d'administration attendent des auditeurs internes qu'ils apportent une vision claire des risques émergents et qu'ils soutiennent la prise de décision.

Cette transformation repose sur un principe simple : l'audit interne doit produire une information utile, fiable et exploitable. Sa valeur dépend de sa capacité à analyser les données pertinentes et à formuler des recommandations éclairées. Dans un environnement de plus en plus digitalisé, cette capacité devient centrale (Eulerich et al., 2019).

Pourtant, dans la pratique, plusieurs services d'audit interne continuent à s'appuyer sur des méthodes traditionnelles. L'échantillonnage, les tests de conformité et les contrôles ponctuels

restent dominants. Ces approches sont utiles, mais elles montrent leurs limites face à des risques nouveaux, rapides et complexes (Lenz & Hahn, 2015 ; Eulerich et al., 2020).

2.2. La fraude financière et les limites des approches traditionnelles :

La fraude financière reste l'un des risques les plus sensibles pour les organisations. Les méthodes classiques de détection reposent principalement sur des règles prédéfinies et des contrôles manuels (Bierstaker et al., 2014). Elles fonctionnent bien pour repérer des irrégularités connues, mais elles sont moins efficaces face à des schémas nouveaux ou dissimulés dans des volumes massifs de données (Kokina & Davenport, 2017).

Dans des environnements fortement digitalisés, les transactions se comptent en milliers, voire en millions, l'échantillonnage devient alors problématique. Il peut laisser passer des anomalies rares mais significatives (Issa et al., 2021). Les approches statistiques traditionnelles montrent également leurs limites lorsqu'il s'agit d'identifier des comportements atypiques non anticipés (Ngai et al., 2011).

C'est pourquoi la littérature récente appelle à un changement de paradigme. Les chercheurs insistent sur la nécessité d'intégrer des approches analytiques avancées capables de traiter des données volumineuses et hétérogènes (Appelbaum et al., 2017 ; Sutton et al., 2023). Le machine learning et l'analytique prédictive apparaissent ainsi comme des outils prometteurs pour détecter des signaux faibles et améliorer la prévention de la fraude.

Mais encore une fois, la technologie seule ne suffit pas. L'efficacité dépend de la manière dont ces outils sont intégrés dans les processus d'audit et de gouvernance. C'est précisément ce lien entre technologie, décision et valeur organisationnelle que la recherche actuelle cherche à mieux comprendre (Eulerich et al., 2020).

2.3. L'analytique avancée et le Machine Learning en audit :

L'essor de l'intelligence artificielle change progressivement la manière dont l'audit est pratiqué (Appelbaum et al., 2017). Le machine learning, en particulier, attire beaucoup d'attention. Contrairement aux systèmes basés sur des règles fixes, ces algorithmes apprennent à partir des

données, ils peuvent repérer des schémas complexes et des comportements inhabituels qui échappent aux contrôles classiques (Appelbaum et al., 2017 ; Issa et al., 2021).

Aujourd'hui, l'analytique avancée permet d'examiner l'ensemble des transactions, et non plus seulement des échantillons. Cette évolution soutient l'idée d'un audit plus continu, plus réactif et plus orienté vers la prévention que vers la simple détection a posteriori (Eulerich et al., 2019 ; Sutton et al., 2023).

Cependant, intégrer le machine learning dans l'audit interne n'est pas simple. Les organisations doivent gérer la qualité des données, adapter leurs systèmes d'information et développer de nouvelles compétences analytiques. La question de la confiance dans les algorithmes et de leur explicabilité devient également centrale (Moll & Yigitbasioglu, 2019 ; Kokina et al., 2021).

Un autre point important ressort des recherches récentes : beaucoup d'études évaluent la performance technique des modèles, mais peu analysent leur impact réel sur le travail quotidien des auditeurs internes (Sutton et al., 2023). Autrement dit, savoir qu'un modèle détecte bien les anomalies ne suffit pas, il faut comprendre comment ces résultats sont utilisés, interprétés et intégrés dans les décisions d'audit.

2.4. La prise de décision augmentée en audit interne :

La littérature récente parle de plus en plus de "prise de décision augmentée". L'idée est simple : les outils analytiques ne remplacent pas l'humain. Ils l'aident à décider mieux et plus vite.

Dans le cas de l'audit interne, cette approche est particulièrement pertinente. Les décisions d'audit sont rarement automatiques ; elles reposent sur l'expérience, le contexte et le jugement professionnel. Le machine learning peut fournir des alertes, signaler des anomalies ou hiérarchiser les risques. Mais c'est l'auditeur qui interprète ces signaux et décide des actions à mener (Alles & Gray, 2016 ; Kokina et al., 2021).

Les travaux récents montrent que la valeur de l'IA réside surtout dans sa capacité à orienter l'attention vers les zones critiques. Elle aide à prioriser, à structurer l'information et à réduire l'incertitude (Sutton et al., 2023). Elle ne supprime pas le jugement professionnel, elle le renforce.

Dans cette perspective, la détection des anomalies financières n'est pas un objectif final, ce n'est qu'une étape.

2.5. Spécificités du contexte marocain :

Les recherches récentes montrent que les outils IA dans les sciences de gestion évoluent de façon rapide mais avec certaines limites (Alzeban, 2019 ; Eulerich et al., 2020). Les systèmes d'information constituent un défi, les ERP sont parfois récents ou partiellement exploités. Les données ne sont pas toujours structurées de manière optimale pour des analyses avancées. Or, l'efficacité du machine learning dépend directement de la qualité des données disponibles (Moll et Yigitbasioglu, 2019 ; Sutton et al., 2023).

Le Maroc reflète bien cette réalité. Les entreprises progressent dans la digitalisation et modernisent leurs pratiques de gouvernance. Mais les écarts restent importants en matière de compétences analytiques et d'intégration de l'IA dans l'audit interne.

Dans ce contexte, le machine learning représente à la fois une opportunité et un défi. Son potentiel est réel mais sa réussite dépend des conditions organisationnelles, du soutien managérial et de la capacité des auditeurs à intégrer ces outils dans leurs décisions. C'est pourquoi une analyse empirique du cas marocain apparaît particulièrement pertinente.

3. Développement des hypothèses de recherche

3.1 Machine Learning et capacité de détection des anomalies financières :

Les méthodes classiques de détection des anomalies financières reposent sur des règles fixes et sur l'échantillonnage. Elles examinent une partie des transactions et cherchent des signaux déjà connus. Cette logique limite l'identification d'anomalies rares ou inédites, comme l'ont montré Bolton et Hand, 2002, ainsi que Bierstaker et al., 2014.

Le machine learning adopte une approche différente. Il analyse l'ensemble des transactions disponibles et détecte des relations complexes, y compris non linéaires. Il repère aussi des comportements atypiques qui échappent aux contrôles traditionnels. (Kogan et al., 2014). Les travaux de Alles et Gray, 2016, confirment que ces techniques élargissent la portée des procédures

d'audit. Vasarhelyi et al., 2015, soulignent leur contribution à la surveillance continue des opérations.

Sur le plan opérationnel, l'intégration du machine learning permet aux auditeurs internes d'identifier plus rapidement des anomalies pertinentes et de réduire le risque de fraude non détectée.

➤ ***Hypothèse 1 (H1) : L'adoption du machine learning a un effet positif sur la capacité de détection des anomalies financières.***

3.2. Détection des anomalies et qualité de la prise de décision :

La détection d'anomalies ne constitue pas un objectif isolé, elle fournit une information qui guide le travail d'audit. Selon les approches cognitives, la qualité du jugement professionnel dépend de la pertinence et de l'organisation des données disponibles (Power, 2004). Lorsque l'information est structurée et hiérarchisée, la décision gagne en cohérence.

Les outils analytiques contribuent à cette structuration. Alles et Gray, 2016, montrent qu'ils aident les auditeurs à prioriser les risques et à cibler les zones sensibles. Appelbaum et al., 2017, indiquent que l'analytique avancée améliore l'allocation des ressources, en orientant l'effort vers les transactions à fort risque.

Une capacité accrue de détection permet donc d'appuyer les jugements sur des signaux plus fiables et plus précis. Elle renforce la qualité des décisions prises lors des missions d'audit interne.

➤ ***Hypothèse 2 (H2) : La capacité de détection des anomalies financières a un effet positif sur la qualité de la prise de décision des auditeurs internes.***

3.3. Qualité de la décision et réduction du risque de fraude :

La littérature en gouvernance présente l'audit interne comme un mécanisme de maîtrise des risques. Toutefois, la réduction effective du risque de fraude ne dépend pas uniquement de l'identification des anomalies. Elle repose sur la qualité des décisions prises ensuite (Sarens et Christopher, 2010).

Bierstaker et al., 2014, montrent que la détection, prise isolément, ne garantit pas l'efficacité du dispositif antifraude. C'est la réponse organisationnelle qui conditionne l'impact réel. Une analyse rapide, une qualification précise du risque et des actions correctives adaptées influencent directement le niveau d'exposition à la fraude.

Lorsque les décisions d'audit sont mieux structurées et ciblent les zones critiques, les mesures mises en place deviennent plus cohérentes et plus efficaces. La réduction du risque découle donc de la qualité du jugement professionnel et de sa traduction opérationnelle.

➤ ***Hypothèse 3 (H3) : La qualité de la prise de décision des auditeurs internes a un effet positif sur la réduction du risque de fraude.***

3.4. Réduction du risque de fraude et création de valeur de l'audit interne :

La valeur ajoutée de l'audit interne dépend de sa contribution réelle à la maîtrise des risques et au renforcement de la gouvernance (Sarens et Christopher, 2010). Lorsque l'audit réduit concrètement le risque de fraude, son rôle devient plus visible au sein de l'organisation.

Une baisse mesurable des incidents frauduleux améliore la crédibilité de la fonction. Les dirigeants disposent d'analyses plus fiables pour piloter les risques. Les parties prenantes accordent davantage de confiance aux mécanismes de contrôle. Cette dynamique consolide la gouvernance et clarifie la responsabilité des acteurs (Bierstaker et al., 2014).

Moll et Yigitbasioglu, 2019, soulignent que l'usage des technologies digitales accroît la légitimité stratégique des fonctions financières lorsqu'elles démontrent un impact direct sur la maîtrise des risques. La perception de valeur repose donc sur des résultats observables.

➤ ***Hypothèse 4 (H4) : La réduction du risque de fraude a un effet positif sur la valeur ajoutée de la fonction d'audit interne.***


3.5. Hypothèse de contribution centrale :

Les travaux récents en audit analytique montrent que l'effet des technologies avancées passe par des mécanismes intermédiaires plutôt que par un impact direct, comme l'indiquent Alles et Gray,

2016. Le machine learning ne génère pas de valeur en soi, il modifie d'abord la manière dont l'information est traitée et exploitée dans le processus d'audit.

Son influence s'exerce en trois étapes liées. Il améliore la détection des anomalies grâce à l'analyse exhaustive des données. Cette détection alimente ensuite des décisions d'audit plus structurées et mieux priorisées. Ces décisions conduisent à des actions correctives plus efficaces, ce qui réduit le risque de fraude (Moll et Yigitbasioglu, 2019). La valeur ajoutée résulte de cette chaîne causale cohérente.

- **Hypothèse 5 (H5 – médiation séquentielle) : *L'effet du machine learning sur la valeur ajoutée de l'audit interne est médié séquentiellement par la détection des anomalies financières, la qualité de la prise de décision et la réduction du risque de fraude.***



4. Méthodologie

4.1. Design de la recherche :

Cette recherche repose sur un design quantitatif séquentiel en deux phases. La première phase est descriptive et exploratoire. Elle identifie les entreprises marocaines disposant des conditions technologiques nécessaires à un audit interne fondé sur l'analytique avancée. Nous retenons comme critères la présence d'un ERP opérationnel et l'usage d'outils d'intelligence artificielle, notamment des algorithmes de machine learning appliqués au contrôle ou à l'audit.

La seconde phase est explicative. Elle teste à l'aide de la méthode PLS-SEM, le modèle reliant l'adoption du machine learning à la détection des anomalies financières, puis à la qualité de la décision, à la réduction du risque de fraude et enfin à la valeur ajoutée de l'audit interne.

Ce dispositif permet d'ancrer l'analyse dans le contexte du tissu économique marocain tout en examinant rigoureusement les relations causales entre les variables étudiées.

4.2. Construction et filtrage de l'échantillon

4.2.1 Source des données :

La première phase mobilise les bases d'information relatives aux clients et partenaires du cabinet marocain SKATYS, spécialisé en audit, conseil et intégration de solutions ERP. Cette source permet d'identifier des entreprises ayant engagé des projets structurés de digitalisation financière, notamment dans les fonctions comptables et de contrôle interne. Elle offre un accès à des organisations déjà exposées aux outils analytiques et aux systèmes intégrés de gestion.

Afin de préserver la rigueur scientifique, le cabinet n'a participé ni au traitement statistique, ni à l'analyse des données, ni à l'interprétation des résultats. L'exploitation des données a été conduite de manière indépendante.

4.2.2 Population et critères de sélection :

La population cible regroupe des entreprises marocaines de taille moyenne et grande opérant dans des secteurs à forte intensité transactionnelle, tels que la finance, l'industrie, les services et le secteur public. Ces environnements génèrent des volumes importants de données, propices à l'usage du machine learning.

Deux critères cumulatifs conditionnent l'inclusion dans la phase explicative. L'entreprise doit disposer d'un ERP opérationnel et déclarer l'utilisation d'un outil de machine learning dédié à la détection d'anomalies ou à la gestion du risque. Sur 73 entreprises identifiées, 41 ne remplissaient pas ces conditions. L'échantillon final comprend 32 entreprises.

4.3. Collecte des données :

Les données ont été recueillies au moyen d'un questionnaire structuré adressé aux responsables de l'audit interne, aux directeurs financiers et aux responsables des systèmes d'information. Ce choix cible des acteurs directement impliqués dans l'usage des outils analytiques et dans la prise de décision liée au contrôle des risques.

Les items sont évalués sur une échelle de Likert en cinq points, allant de 1, pas du tout d'accord, à 5, tout à fait d'accord. Les construits mesurés portent sur :

- Adoption du machine learning,
- Capacité de détection des anomalies financières,
- Qualité de la prise de décision,
- Réduction du risque de fraude,
- Valeur ajoutée de l'audit interne.

Les échelles ont été adaptées de travaux validés en audit analytique et en gouvernance, notamment ceux d'Alles et Gray, 2016, Appelbaum et al., 2017, et Sarens et Christopher, 2010.

4.4. Spécification du modèle structurel :


Le modèle structurel testé repose sur les équations suivantes :

$$ANOM = \beta_1 ML + \varepsilon_1$$

$$DEC = \beta_2 ANOM + \varepsilon_2$$

$$FRAUD = \beta_3 DEC + \varepsilon_3$$

$$VALUE = \beta_4 FRAUD + \varepsilon_4$$



Avec :

ANOM : Capacité de détection des anomalies financières ;

ML : Niveau d'adoption du Machin Learning ;

β_1 : Coefficient de chemin ;

ε_1 : Terme d'erreur

Les effets indirects sont calculés comme suit :

$$Effet_{indirect} = \beta_1 \times \beta_2 \times \beta_3 \times \beta_4$$

Cette spécification permet de tester une médiation séquentielle complète, conformément au cadre théorique.

4.5 Justification du choix du PLS-SEM :

Le recours au PLS-SEM se justifie par des considérations méthodologiques précises. L'échantillon est de taille modérée, $n = 32$, ce qui rend cette approche plus appropriée que les méthodes basées sur la covariance. Le modèle présente une logique prédictive et intègre des médiations séquentielles, ce qui implique des relations structurelles complexes. Les variables sont mesurées à partir d'échelles ordinales de type Likert, compatibles avec l'estimation PLS.

Selon Hair et al., 2019, le PLS-SEM convient aux recherches exploratoires, aux modèles complexes et aux contextes empiriques encore peu stabilisés, comme l'usage du machine learning en audit interne au Maroc.

4.6. Évaluation du modèle et considérations méthodologiques :

L'évaluation du modèle a suivi la procédure en deux étapes recommandée en PLS-SEM. Le modèle de mesure a été examiné en premier afin d'assurer la fiabilité et la validité des construits. Les seuils retenus étaient conformes aux standards méthodologiques, avec un alpha de Cronbach et une fiabilité composite supérieurs à 0,70, ainsi qu'une AVE supérieure à 0,50. La validité discriminante a été vérifiée à l'aide du critère de Fornell-Larcker. Les résultats confirment la robustesse des instruments de mesure.

Le modèle structurel a ensuite été analysé à partir des coefficients de chemin β et des coefficients de détermination R^2 des variables endogènes. La significativité des relations a été testée par bootstrap, 5 000 répliques, avec un seuil de p inférieur à 0,05. Les effets indirects ont été estimés pour examiner la médiation séquentielle.

Les données ont été traitées de manière confidentielle et anonymisée, et les répondants ont été informés du caractère académique de l'étude. Les limites portent sur la taille de l'échantillon, la nature déclarative des réponses et la sélection initiale des entreprises.

5. Résultats

5.1 Statistiques descriptives et sélection de l'échantillon :

L'étude s'appuie initialement sur 73 entreprises marocaines opérant dans des secteurs à forte intensité transactionnelle (Logistique, les services financiers, commerce et télécoms). Un filtrage méthodologique a été appliqué afin de retenir uniquement les organisations répondant à deux critères cumulatifs : la présence d'un système ERP opérationnel et l'utilisation déclarée d'un outil d'intelligence artificielle, en particulier de machine learning, à des fins d'audit, de contrôle ou de détection d'anomalies financières.

Au terme de cette sélection, 41 entreprises ont été exclues pour non-conformité aux critères. L'échantillon final de la phase explicative comprend 32 entreprises, représentant des organisations technologiquement équipées pour déployer un audit interne fondé sur l'analytique avancée.

Les statistiques descriptives indiquent, que dans cet échantillon, des niveaux élevés pour les principales dimensions étudiées, notamment l'adoption du machine learning, la capacité de détection des anomalies, la qualité de la décision, la réduction du risque de fraude et la valeur ajoutée perçue de l'audit interne. Ces premiers résultats suggèrent un ancrage réel des pratiques analytiques dans ces entreprises.

5.2 Évaluation du modèle de mesure (PLS-SEM) :

Avant l'analyse du modèle structurel, la qualité du modèle de mesure a été examinée à l'aide du logiciel SmartPLS 4, conformément à la procédure PLS-SEM. Les coefficients ont été obtenus par estimation itérative des charges factorielles externes.

La fiabilité interne a été évaluée par l'alpha de Cronbach et la fiabilité composite (CR). Les valeurs observées dépassent 0,70, seuil recommandé par Hair et al. (2019), indiquant une cohérence satisfaisante des items au sein de chaque construit. La validité convergente a été vérifiée via l'Average Variance Extracted (AVE), dont les valeurs sont supérieures à 0,50, ce qui signifie que chaque construit explique plus de 50 % de la variance de ses indicateurs.

La validité discriminante a été testée selon le critère de Fornell–Larcker. Pour chaque variable latente, la racine carrée de l'AVE est supérieure aux corrélations inter-constructs, confirmant une distinction empirique adéquate entre les concepts mesurés. Ces résultats confirment que les échelles de mesure utilisées sont appropriées pour tester le modèle structurel.

5.3 Résultats du modèle structurel :

Le modèle a été estimé avec SmartPLS selon l'approche PLS-SEM en utilisant un bootstrap de 5 000 répliques. Les coefficients β indiquent l'intensité et le sens de la relation entre deux variables. Plus β est proche de 1, plus l'effet est fort. En sciences de gestion, un coefficient autour de 0,10 est considéré comme faible, autour de 0,30 comme modéré, et au-delà de 0,50 comme élevé. La significativité statistique au seuil de 5 % est confirmée lorsque la valeur t dépasse 1,96 et que la p -value est inférieure à 0,05.

Tableau 1. Résultats du modèle structurel

Hypothèse	Relation	Coefficient (β)	t	p-value
H1	ML $\rightarrow$ Anomalies	0,41	2,12	0,034
H2	Anomalies $\rightarrow$ Décision	0,38	1,98	0,048
H3	Décision $\rightarrow$ Fraude	0,44	2,26	0,026
H4	Fraude $\rightarrow$ Valeur ajoutée	0,47	2,41	0,019

Source : Sortie SmartPLS

Ces résultats montrent que l'ensemble des relations hypothétisées est positif et statistiquement significatif :

- L'adoption du machine learning exerce un effet positif sur la capacité de détection des anomalies financières ($\beta = 0,41$; $t = 2,12$; $p = 0,034 < 0,05$). Cela signifie qu'une augmentation de l'usage du machine learning s'accompagne d'une amélioration tangible de la détection.
- La capacité de détection des anomalies améliore la qualité de la prise de décision des auditeurs internes ($\beta = 0,38$; $t = 1,98$; $p = 0,048 < 0,05$). Cela signifie qu'une meilleure identification des anomalies améliore la pertinence des décisions.
- La qualité de la prise de décision contribue significativement à la réduction du risque de fraude ($\beta = 0,44$; $t = 2,26$; $p = 0,026 < 0,05$).
- La réduction du risque de fraude renforce la valeur ajoutée de la fonction d'audit interne ($\beta = 0,47$; $t = 2,41$; $p = 0,019 < 0,05$).

Ces résultats confirment que le machine learning joue un rôle structurant dans la chaîne décisionnelle de l'audit interne.

5.4 Application des équations structurelles :

Les relations estimées peuvent être formalisées par les équations suivantes :

Équation 1 – Détection des anomalies financières

$$ANOM = \beta_1 \cdot ML + \varepsilon_1$$

En remplaçant par les valeurs estimées :

$$ANOM = 0,41 \cdot ML + \varepsilon_1$$

- **Interprétation empirique** : Une augmentation d'1 point du niveau d'adoption du machine learning entraîne une augmentation moyenne de **0,41 point** de la capacité de détection des anomalies financières.

Équation 2 – Qualité de la prise de décision

$$DEC = \beta_2 \cdot ANOM + \varepsilon_2$$

$$DEC = 0,38 \cdot ANOM + \varepsilon_2$$

- Une amélioration de la détection des anomalies de 1 point améliore la qualité décisionnelle de **0,38 point**.

Équation 3 – Réduction du risque de fraude

$$FRAUD = \beta_3 \cdot DEC + \varepsilon_3$$

$$FRAUD = 0,44 \cdot DEC + \varepsilon_3$$

- Une décision d'audit plus qualitative se traduit par une réduction du risque de fraude de **0,44 point**.

Équation 4 – Valeur ajoutée de l’audit interne

$$VALUE = \beta_4 \cdot FRAUD + \varepsilon_4$$

$$VALUE = 0,47 \cdot FRAUD + \varepsilon_4$$

- La réduction du risque de fraude contribue directement à la **création de valeur de l’audit interne**.

Ces équations montrent que l’impact du machine learning sur la valeur ajoutée de l’audit interne ne s’exerce pas de manière directe, mais à travers une chaîne séquentielle de médiations.

5.5. Application des formules de médiation et effets indirects :

Les tests de médiation réalisés par bootstrap mettent en évidence des effets indirects significatifs. Ces effets apparaissent lorsqu’une variable influence une autre à travers un ou plusieurs médiateurs. Dans un modèle PLS-SEM, ils sont calculés en multipliant les coefficients des relations successives.

5.5.1 Médiation simple :

$$ML \rightarrow ANOM \rightarrow DEC$$

$$Effet_{indirect1} = \beta_1 \times \beta_2$$

$$Effet_{indirect1} = 0,41 \times 0,38 = 0,156$$

- **Interprétation :** Le machine learning améliore la qualité décisionnelle **indirectement** à hauteur de **0,156** unité via la détection des anomalies. L’effet est modéré et statistiquement significatif selon le bootstrap, ce qui confirme l’existence d’un mécanisme intermédiaire.

5.5.2 Médiation séquentielle :

$$ML \rightarrow ANOM \rightarrow DEC \rightarrow FRAUD$$

$$Effet_{indirect2} = \beta_1 \times \beta_2 \times \beta_3$$

$$Effet_{indirect2} = 0,41 \times 0,38 \times 0,44 = 0,069$$

- **Interprétation :** Le machine learning réduit le risque de fraude **de manière indirecte**, via un processus décisionnel structuré. L'effet est plus faible car il traverse trois relations successives. Il reste toutefois significatif. Cela montre que la réduction du risque de fraude ne résulte pas d'un effet direct du machine learning, mais d'un enchaînement : meilleure détection, décision plus pertinente, puis action corrective plus efficace.

5.5.3 Médiation totale :

La médiation totale examine l'effet du machine learning sur la valeur ajoutée de l'audit interne à travers l'ensemble de la chaîne causale : détection des anomalies, qualité de la décision, réduction du risque de fraude, puis création de valeur.

$$ML \rightarrow ANOM \rightarrow DEC \rightarrow FRAUD \rightarrow VALUE$$

$$Effet_{indirect total} = \beta_1 \times \beta_2 \times \beta_3 \times \beta_4$$

$$Effet_{indirect total} = 0,41 \times 0,38 \times 0,44 \times 0,47 = 0,032$$

- **Interprétation :** L'effet indirect total correspond au produit des coefficients successifs : $0,41 \times 0,38 \times 0,44 \times 0,47 = 0,032$. Ce coefficient indique qu'une augmentation d'une unité de l'adoption du machine learning entraîne une hausse de 0,032 unité de la valeur ajoutée via ce mécanisme complet. La valeur numérique est modérée, ce qui est attendu dans une médiation longue où chaque étape filtre une partie de l'effet initial.

La significativité confirmée par bootstrap montre que cet effet n'est pas dû au hasard. Sur le plan théorique, le résultat est central : la valeur ajoutée ne provient pas directement de l'IA, mais du

processus organisationnel qu'elle structure, en améliorant l'information, la décision et la maîtrise du risque.

5.5. Explication du modèle :

Les coefficients de détermination (R^2) permettent d'évaluer le pouvoir explicatif du modèle pour chaque variable endogène. Les résultats montrent une progression cohérente le long de la chaîne causale.

Tableau 2. Résultats des coefficients de détermination

Variable endogène	R ²
Détection anomalies	0,17
Qualité décision	0,22
Réduction fraude	0,29
Valeur ajoutée audit	0,31

Source : Sortie SmartPLS

L'adoption du machine learning explique 17 % de la variance de la capacité de détection des anomalies financières ($R^2 = 0,17$). Ce niveau est considéré comme faible à modéré, ce qui est fréquent dans les recherches organisationnelles portant sur des phénomènes complexes.

La détection des anomalies explique 22 % de la variance de la qualité de la décision ($R^2 = 0,22$), puis la qualité décisionnelle explique 29 % de la réduction du risque de fraude ($R^2 = 0,29$). Et enfin, 31 % de la variance de la valeur ajoutée de l'audit interne est expliquée par la réduction du risque ($R^2 = 0,31$). Selon les standards en sciences de gestion, des niveaux de R^2 compris entre 0,20 et 0,40 traduisent un pouvoir explicatif substantiel, en particulier avec un échantillon de 32 entreprises.

Ces résultats soutiennent l'idée d'un audit interne intelligent orienté décision, dans lequel les outils de machine learning renforcent le jugement professionnel plutôt que de s'y substituer. Le machine learning n'agit pas directement, mais crée de la valeur via la décision : il améliore la qualité de l'information, renforce la décision, réduit le risque, puis accroît la valeur perçue de l'audit interne.

Le machine learning améliore la valeur ajoutée de l'audit interne uniquement lorsqu'il est intégré dans un processus décisionnel structuré, fondé sur la détection d'anomalies et la gestion proactive du risque de fraude.

6. Discussion

6.1. Contribution théorique principale :

Cette recherche contribue au débat théorique sur l'articulation entre audit interne et intelligence artificielle. Les résultats montrent que le machine learning ne génère pas de valeur par un effet direct sur la performance. Son influence s'exerce à travers un mécanisme socio-technique structurant les processus informationnels et décisionnels.

Le modèle PLS-SEM met en évidence une médiation complète : l'adoption du machine learning améliore la détection des anomalies financières, renforce la qualité du jugement professionnel, puis contribue à la réduction du risque de fraude. La valeur ajoutée de l'audit interne découle de cette dynamique structurée.

Ce résultat prolonge les travaux d'Alles et Gray (2016), d'Appelbaum et al. (2017) et de Vasarhelyi et al. (2015), qui soulignent que l'apport des outils analytiques de l'IA en audit dépend de leur intégration dans les routines organisationnelles. La performance algorithmique soutient donc le jugement de l'auditeur, mais ne s'y substitue pas.

6.2. Discussion des résultats paradoxaux entre analyses OLS et PLS-SEM :

Un résultat notable concerne l'écart entre les analyses des moindres carrés ordinaires (OLS) et le modèle PLS-SEM. Les régressions linéaires n'ont pas identifié de relations directes significatives, alors que le PLS-SEM met en évidence des effets indirects statistiquement significatifs via des médiations séquentielles.

Cette divergence s'explique d'abord par la taille réduite de l'échantillon ($n = 32$), mieux adaptée à l'approche PLS, moins exigeante en termes de normalité et de puissance statistique. Elle tient aussi à la structure du phénomène étudié. La création de valeur en audit interne ne suit pas une relation linéaire simple, elle repose sur une chaîne cumulative reliant information, décision et gestion du risque.

Ce travail de recherche montre que les approches traditionnelles peuvent sous-estimer les mécanismes intermédiaires, alors que le PLS-SEM permet de modéliser plus finement la dynamique décisionnelle associée à l'usage du machine learning.

6.3. Implications pour la littérature sur la fraude et le contrôle interne :

Les résultats enrichissent les travaux consacrés à la prévention et à la gestion du risque de fraude. L'étude ne réduit pas le machine learning à un outil technique de détection. Elle montre que son efficacité dépend de son intégration dans les dispositifs de contrôle interne, dans les mécanismes de priorisation des risques et dans la gouvernance de l'audit interne.

La réduction du risque de fraude apparaît comme un résultat organisationnel émergent. Elle découle de l'articulation entre technologie, jugement professionnel et cadre de gouvernance. L'automatisation, prise isolément, ne suffit pas à produire cet effet.

Cette perspective dépasse les modèles centrés sur la seule détection des anomalies. Elle met en avant une logique préventive, fondée sur la qualité de la décision et sur la capacité de l'organisation à transformer l'information analytique en action de contrôle structurée.

6.4. Spécificité du contexte marocain et portée des résultats :

Le contexte marocain confère à cette étude un intérêt analytique spécifique. Le processus de sélection a conduit à exclure plus de la moitié des entreprises initialement identifiées, ce qui révèle une hétérogénéité marquée en matière de maturité technologique. Toutes les organisations ne disposent pas des infrastructures nécessaires pour intégrer l'analytique avancée dans leurs pratiques d'audit interne.

En revanche, les entreprises équipées d'un ERP opérationnel et d'outils de machine learning affichent des niveaux élevés de performance perçue en matière de détection des anomalies, de qualité décisionnelle et de réduction du risque de fraude.

Ces résultats suggèrent que l'enjeu central ne réside pas dans la sophistication des algorithmes, mais dans la capacité organisationnelle à structurer leur usage, à les intégrer aux processus de contrôle et à soutenir le jugement professionnel des auditeurs.

7. Conclusion et implications :

Cette recherche analyse le rôle du machine learning dans l'évolution de l'audit interne au sein des entreprises marocaines. À partir d'un design quantitatif séquentiel et d'une modélisation PLS-SEM, les résultats montrent que le Machine Learning n'exerce pas d'effet direct sur la valeur ajoutée. Son influence suit une chaîne structurée : amélioration de la détection des anomalies financières, renforcement de la qualité du jugement professionnel, réduction du risque de fraude, puis accroissement de la valeur perçue de la fonction d'audit interne.

Ces résultats prolongent les travaux de Sarens et Christopher (2010), qui positionnent l'audit interne comme mécanisme central de gouvernance, ainsi que ceux de Vasarhelyi et al. (2015) et Alles et Gray (2016), qui conçoivent l'intelligence artificielle comme un outil d'augmentation du jugement plutôt que de substitution. La création de valeur apparaît ainsi comme un processus organisationnel médié par la décision.

Sur le plan managérial, trois conditions ressortent : disposer d'infrastructures robustes, intégrer le machine learning aux routines décisionnelles, et développer les compétences analytiques des auditeurs. L'enjeu principal demeure la qualité du jugement appuyé par l'analytique. Ces résultats ouvrent la voie à des travaux comparatifs et à l'étude du Deep Learning dans des dispositifs d'audit continu.

Toutefois, malgré ses contributions, cette étude présente des limites méthodologiques. La taille relativement réduite de l'échantillon limite la généralisation des résultats, bien que l'utilisation du PLS-SEM atténue partiellement cette contrainte. De plus, une partie des données repose sur des perceptions déclaratives, ce qui peut introduire un biais lié à l'auto-évaluation des pratiques et des performances.

Ces limites ouvrent plusieurs pistes de recherche. L'intégration de données transactionnelles réelles permettrait de confronter les perceptions aux performances observées. L'analyse de techniques de Deep Learning dans des dispositifs d'audit continu offrirait un prolongement naturel. L'étude de variables modératrices, telles que la culture organisationnelle, la maturité de la gouvernance ou les

compétences analytiques des auditeurs, permettrait d'affiner la compréhension des conditions d'efficacité.

BIBLIOGRAPHIE

- Alzeban, A. (2019). L'impact du comité d'audit, du dirigeant général et de la qualité de l'auditeur externe sur la qualité de l'audit interne. *Journal of Applied Accounting Research*, 20(1), 73–89.
- Alzeban, A., & Gwilliam, D. (2014). Les facteurs influençant l'efficacité de l'audit interne : Une étude du secteur public saoudien. *Journal of International Accounting, Auditing and Taxation*, 23(2), 74–86.
- Alles, M. G., & Gray, G. L. (2016). L'intégration des mégadonnées en audit : Identification des freins et agenda de recherche. *International Journal of Accounting Information Systems*, 22, 44–59.
- Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big data et analytique dans l'audit moderne : Besoins de recherche. *Accounting Horizons*, 31(1), 1–27.
- Bierstaker, J. L., Brody, R. G., & Pacini, C. (2014). Méthodes de détection et de prévention de la fraude en comptabilité. *Journal of Forensic Accounting Research*, 1(1), A1–A23.
- Bolton, R. J., & Hand, D. J. (2002). La détection statistique de la fraude : Une revue de la littérature. *Statistical Science*, 17(3), 235–255.
- Eulerich, M., Theis, J., & Velte, P. (2019). La taille de la fonction d'audit interne est-elle déterminante ? Une analyse empirique. *Managerial Auditing Journal*, 34(7), 828–856.
- Eulerich, M., Kremin, J., & Wood, D. A. (2020). Les facteurs influençant l'utilisation perçue de la fonction d'audit interne. *Journal of Accounting & Organizational Change*, 16(2), 215–236.

- Institute of Internal Auditors (IIA). (2020). *Cadre international des pratiques professionnelles (IPPF)*. The Institute of Internal Auditors.
- Issa, H., Sun, T., & Vasarhelyi, M. A. (2021). Pistes de recherche sur l'intelligence artificielle en audit : Formalisation de l'audit et complémentarité homme-machine. *Journal of Emerging Technologies in Accounting*, 18(1), 1–20.
- Kogan, A., Alles, M. G., & Vasarhelyi, M. A. (2014). L'utilisation de l'analytique des données en audit. *Accounting Horizons*, 28(2), 349–366.
- Kokina, J., & Davenport, T. H. (2017). L'émergence de l'intelligence artificielle : Comment l'automatisation transforme l'audit. *Journal of Emerging Technologies in Accounting*, 14(1), 115–122.
- Kokina, J., Pachamanova, D., & Corbett, A. (2021). Le rôle de l'analytique des données et de l'intelligence artificielle dans la transformation de l'audit. *Accounting Horizons*, 35(4), 125–149.
- Lenz, R., & Hahn, U. (2015). Synthèse des recherches empiriques sur l'efficacité de l'audit interne et perspectives futures. *Journal of Accounting Literature*, 35, 1–27.
- Mihret, D. G., James, K., & Mula, J. M. (2010). Antécédents et implications organisationnelles de l'efficacité de l'audit interne. *Managerial Auditing Journal*, 25(3), 224–252.
- Moll, J., & Yigitbasioglu, O. (2019). Le rôle des technologies numériques en comptabilité et en audit. *The British Accounting Review*, 51(6), 100833.
- Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). L'application des techniques de data mining à la détection de la fraude financière : Cadre de classification et revue académique. *Decision Support Systems*, 50(3), 559–569.
- Power, M. (2004). *La gestion du risque de tout : Repenser la politique de l'incertitude*. Demos.

- Roussy, M., & Brivot, M. (2016). La qualité de l'audit interne : Une analyse polyphonique. *Accounting, Organizations and Society*, 53, 1–25.
- Sarens, G., & Christopher, J. (2010). L'association entre les lignes directrices de gouvernance et les pratiques de gestion des risques et de contrôle interne. *Managerial Auditing Journal*, 25(4), 288–308.
- Sutton, S. G., Holt, M., & Arnold, V. (2023). Intelligence artificielle et audit : Tendances actuelles et perspectives futures. *Accounting Horizons*, 37(2), 89–110.
- Vasarhelyi, M. A., Kogan, A., & Tuttle, B. M. (2015). Les mégadonnées en comptabilité : Une vue d'ensemble. *Accounting Horizons*, 29(2), 381–396.