

L'usage de l'intelligence artificielle dans la prévision financière et la qualité de la décision stratégique : rôle médiateur de la qualité perçue des prévisions dans les entreprises marocaines

The Use of Artificial Intelligence in Financial Forecasting and Strategic Decision Quality: The Mediating Role of Perceived Forecast Quality in Moroccan Firms

Mohamed Yassir TADLAOUI, (Doctorant)

*Faculté d'économie et de gestion de Fès
Université Sidi Mohamed Ben Abdellah, Fès, Maroc*

Karim BENNIS, (Enseignant-Chercheur)

*Faculté d'économie et de gestion de Fès
Université Sidi Mohamed Ben Abdellah, Fès, Maroc*

Adresse de correspondance :	Faculté d'Économie et de Gestion de Fès (FEG Fès)
Déclaration de divulgation :	Les auteurs n'ont pas connaissance de quelconque financement qui pourrait affecter l'objectivité de cette étude. Ils assument l'entière responsabilité de tout éventuel plagiat, de l'usage de l'intelligence artificielle dans la rédaction, ainsi que des résultats présentés dans cet article.
Conflit d'intérêts :	Les auteurs ne signalent aucun conflit d'intérêts.
Citer cet article	TADLAOUI, M. Y., & BENNIS, K. (2026). L'usage de l'intelligence artificielle dans la prévision financière et la qualité de la décision stratégique : rôle médiateur de la qualité perçue des prévisions dans les entreprises marocaines. <i>International Journal of Accounting, Finance, Auditing, Management and Economics</i> , 7(13), 626–648. https://doi.org/10.5281/zenodo.23601123
Licence	Cet article est publié en open Access sous licence CC BY-NC-ND

Received: 30/09/2026

Accepted: 30/10/2026

International Journal of Accounting, Finance, Auditing, Management and Economics - IJAFAME

ISSN: 2658-8455

Volume 7, Issue 13 (2026)

L'usage de l'intelligence artificielle dans la prévision financière et la qualité de la décision stratégique : rôle médiateur de la qualité perçue des prévisions dans les entreprises marocaines

Résumé

Les entreprises intègrent progressivement des outils d'intelligence artificielle (IA) dans leurs activités de prévision financière, mais les travaux consacrés au contexte marocain portent surtout sur la performance prédictive des modèles et peu sur la manière dont la prévision est mobilisée dans la décision. Cette étude comble ce vide en examinant si l'usage de l'IA dans la prévision financière et la qualité des données sont associés à la qualité perçue des prévisions, et si celle-ci est associée à la qualité de la décision stratégique. Elle contribue à la littérature en spécifiant la qualité perçue des prévisions comme mécanisme statistique de transmission entre l'usage de l'IA et la décision. Le design est mixte imbriqué, à dominante quantitative : dix entretiens exploratoires apportent un cadrage contextuel, puis une enquête non probabiliste auprès de 250 professionnels de la finance et du pilotage d'entreprises marocaines est analysée par PLS-SEM. Les résultats indiquent des associations positives, de force modérée à faible : la qualité des données ($\beta = 0,259$) et, davantage, l'usage de l'IA ($\beta = 0,364$) sont associés à la qualité perçue des prévisions ($R^2 = 0,250$), elle-même associée à la qualité décisionnelle ($\beta = 0,334$; $R^2 = 0,207$). L'effet indirect de l'usage de l'IA sur la décision est significatif ($\beta = 0,121$), à côté d'un effet direct ($\beta = 0,197$), ce qui correspond à une médiation statistique partielle complémentaire. Les entretiens et la question ouverte soulignent la gouvernance des données, la supervision humaine et l'accompagnement des utilisateurs, sans que le modèle les teste. Le plan transversal, la mesure perceptuelle et la validation incomplète des items appellent à la prudence dans l'interprétation.

Mots clés : intelligence artificielle, prévision financière, qualité des données, qualité perçue des prévisions, qualité de la décision, médiation, PLS-SEM.

JEL Classification : C45, C53, D81, M15, M41, O33.

Type du papier : Recherche empirique.

Abstract

As finance functions digitalize, firms increasingly integrate artificial intelligence (AI) tools into forecasting, yet research on Morocco has mainly examined the predictive performance of models and says little about how forecasts are used in decisions. This study addresses this gap by examining whether AI use in financial forecasting and data quality are associated with perceived forecast quality, and whether the latter is associated with strategic decision quality. It contributes by specifying perceived forecast quality as a statistical transmission mechanism between AI use and decision quality. The study adopts an embedded mixed-methods design with quantitative dominance: ten exploratory interviews provide contextual framing, followed by a non-probability survey of 250 finance and management-control professionals in Moroccan firms, analyzed with PLS-SEM. Results show positive associations of moderate to small magnitude: data quality ($\beta = 0.259$) and, to a greater extent, AI use ($\beta = 0.364$) are associated with perceived forecast quality ($R^2 = 0.250$), which is in turn associated with decision quality ($\beta = 0.334$; $R^2 = 0.207$). The indirect effect of AI use on decision quality is significant ($\beta = 0.121$; 95% CI [0.070, 0.183]) alongside a significant direct effect ($\beta = 0.197$), indicating complementary partial statistical mediation. Interviews and an open-ended question point to data governance, human oversight, and user support as enabling conditions, which the model does not test. The study thus shifts attention from algorithmic performance alone to the organizational appropriation of AI-assisted forecasting. The cross-sectional design, the perceptual measurement of forecast quality, and the incomplete validation of the items call for caution in interpreting the findings.

Keywords: artificial intelligence, financial forecasting, data quality, perceived forecast quality, decision quality, mediation, PLS-SEM.

JEL Classification: C45, C53, D81, M15, M41, O33.

Paper type: Empirical Research.

1. Introduction

La prévision financière occupe une place centrale dans le pilotage de l'entreprise. Les décisions de trésorerie, d'investissement, de financement, d'allocation des ressources ou de gestion des risques supposent toutes une représentation crédible de situations futures qui demeurent, par définition, incertaines. Prévoir ne revient pas seulement à produire une valeur future : il s'agit de transformer l'information disponible en un support de planification, de coordination et d'arbitrage (Petropoulos et al., 2022). Cette fonction devient plus exigeante lorsque les données se multiplient, que la volatilité augmente et que les interdépendances échappent aux modèles linéaires ou aux procédures budgétaires figées.

Dans ce contexte, l'intelligence artificielle (IA) et les techniques d'apprentissage automatique ont élargi le répertoire des méthodes de prévision. Plusieurs travaux montrent que certaines architectures peuvent dépasser des méthodes plus traditionnelles sur des séries de marché (Fischer & Krauss, 2018 ; Sezer et al., 2020), mais ces résultats concernent la prévision des marchés financiers, non les prévisions budgétaires, de trésorerie ou de planification produites au sein de l'entreprise. Pour cette seconde famille de tâches, les travaux sur l'apprentissage automatique appliqué aux données comptables suggèrent des gains de précision dans la prévision des résultats (Chen et al., 2022). Les compétitions de prévision rappellent toutefois que les méthodes d'apprentissage ne dominent pas systématiquement les méthodes statistiques simples et que la performance dépend du protocole de validation (Makridakis et al., 2018, 2022).

La question managériale ne se confond pas avec la question algorithmique. Une entreprise peut disposer d'un modèle techniquement performant sans que ses prévisions soient jugées suffisamment fiables, compréhensibles, rapides ou pertinentes pour être intégrées aux décisions. Dans cet article, l'IA est entendue, à la suite de Kaplan et Haenlein (2019), comme la capacité d'un système à interpréter correctement des données, à apprendre de ces données et à utiliser cet apprentissage pour accomplir des tâches précises. L'objet étudié, « l'usage de l'IA dans la prévision financière », désigne le recours régulier à des outils d'apprentissage automatique ou d'analyse prédictive, y compris les fonctionnalités prédictives intégrées aux progiciels de gestion (ERP) et aux outils de Business Intelligence (BI), pour produire des prévisions budgétaires, de trésorerie ou de planification. Il ne désigne ni l'automatisation simple ni l'usage d'un tableur sans fonction prédictive.

Le terrain marocain illustre cet enjeu. La stratégie nationale Digital Morocco 2030, lancée en septembre 2024 (Hespress, 2024), est déclinée dans le domaine de l'IA par la feuille de route Maroc IA 2030, dont les principales avancées ont été présentées en septembre 2026 et qui vise notamment 100 milliards de dirhams de valeur ajoutée à l'horizon 2030 (Ministère de la Transition numérique et de la Réforme de l'administration, 2026). Une enquête Concentrix-Ipsos menée auprès de 150 entreprises marocaines rapporte que 96 % d'entre elles utilisent déjà l'IA ou l'automatisation dans leur expérience client et que 90 % envisagent d'accélérer cette adoption dans les douze mois (Concentrix & Ipsos, 2026), même si cette enquête porte sur la relation client et non sur la fonction financière. Du côté académique, les travaux consacrés aux données financières marocaines portent surtout sur la performance prédictive des modèles, qu'il s'agisse de la rentabilité des entreprises (Jamil et al., 2026a) ou de la création de valeur actionnariale (Jamil et al., 2026b). À notre connaissance, et sans prétendre à l'exhaustivité d'une recension systématique, ces recherches disent peu de ce qui se passe lorsque la prévision entre dans l'organisation : comment les professionnels en apprécient la qualité, et dans quelle mesure cette appréciation est associée à la décision stratégique. Nous n'avons pas identifié d'étude qui articule simultanément, dans un contexte émergent, la qualité des données, la qualité perçue des prévisions et la qualité décisionnelle.

La question de recherche est la suivante : dans quelle mesure l'usage de l'IA dans la prévision financière et la qualité des données sont-ils associés à la qualité perçue des prévisions, et dans quelle mesure celle-ci est-elle associée à la qualité des décisions stratégiques des entreprises marocaines ? Elle se décline en cinq sous-questions articulées aux hypothèses : la qualité des données est-elle associée à la qualité perçue des prévisions (H1) ? L'usage de l'IA l'est-il (H2) ? La qualité perçue des prévisions est-elle associée à la qualité de la décision (H3) ? L'usage de l'IA est-il directement associé à cette dernière (H4) ? La qualité perçue des prévisions relaie-t-elle statistiquement l'association entre l'usage de l'IA et la décision (H5) ?

L'article apporte trois contributions. Sur le plan théorique, il prolonge la chaîne « qualité de l'information, usage, bénéfices » du modèle de succès des systèmes d'information (DeLone & McLean, 2003) en la spécifiant pour la prévision financière assistée par l'IA : la qualité perçue des prévisions y est traitée comme la qualité de l'information produite par l'outil et comme mécanisme de transmission entre l'usage de l'IA et la décision, et non comme un antécédent de l'usage. Sur le plan empirique, il propose un test sur 250 entreprises marocaines, complété par une évaluation de la capacité prédictive du modèle. Sur le plan managérial, il éclaire les conditions organisationnelles (gouvernance des données, coordination entre la fonction financière et la direction des systèmes d'information (DSI), supervision humaine, accompagnement des utilisateurs) qui ressortent de la phase exploratoire. L'article présente successivement le cadre théorique et les hypothèses, la méthodologie, les résultats, leur discussion et la conclusion.

2. Revue de littérature et développement des hypothèses

2.1. Un cadre théorique intégrateur

La littérature mobilisée relève de quatre courants : les capacités analytiques et d'IA (Gupta & George, 2016 ; Mikalef & Gupta, 2021), le modèle de succès des systèmes d'information (DeLone & McLean, 2003), l'adéquation tâche-technologie (Goodhue & Thompson, 1995) et les travaux sur l'interaction entre humains et algorithmes (Dietvorst et al., 2015 ; Logg et al., 2019 ; Raisch & Krakowski, 2021). Ils sont ici articulés autour du modèle de succès des systèmes d'information, qui fournit l'ossature du modèle : la qualité de l'information et l'usage du système précèdent des bénéfices nets, ici la qualité de la décision. Deux apports complètent cette ossature. D'une part, la théorie des ressources et des capacités explique pourquoi la technologie seule ne suffit pas : Gupta et George (2016) conceptualisent la capacité d'analyse des données comme un assemblage de ressources tangibles, humaines et immatérielles, Mikalef et Gupta (2021) l'étendent à l'IA, et Jöhnk et al. (2021) identifient l'alignement stratégique, les ressources, les connaissances, la culture et les données parmi les dimensions de la préparation organisationnelle à l'IA. D'autre part, l'adéquation tâche-technologie suggère que la performance d'un outil dépend de son adéquation à la tâche qu'il soutient (Goodhue & Thompson, 1995) : une prévision n'améliore la décision que si les utilisateurs la jugent adaptée à leurs besoins, ce qui justifie de placer la qualité perçue des prévisions entre l'usage de l'outil et la décision.

Le modèle proposé reprend ainsi, pour une large part, la logique du modèle de succès des systèmes d'information. Sa spécificité tient à trois éléments. Premièrement, l'information dont on évalue la qualité est une prévision produite par un outil d'IA, et non une information générique : la qualité perçue des prévisions est donc traitée comme un résultat de l'usage de l'IA et comme un déterminant de la décision. Deuxièmement, la qualité des données est positionnée comme une qualité d'entrée du processus de prévision, distincte de la qualité de sa sortie. Troisièmement, la littérature sur l'interaction entre humains et algorithmes conduit à ne pas supposer que l'usage d'un outil d'IA se traduit mécaniquement par un jugement favorable : les décideurs peuvent se défier d'un algorithme après avoir constaté ses erreurs (Dietvorst et

al., 2015) ou, au contraire, lui accorder davantage de poids qu'à un avis humain (Logg et al., 2019), et la valeur de l'IA dépend de la manière dont elle complète le jugement humain (Raisch & Krakowski, 2021 ; Shrestha et al., 2019).

2.2. Intelligence artificielle, capacités analytiques et prévision financière

Le machine learning complète les approches statistiques classiques en autorisant des relations non linéaires, des interactions complexes et des structures temporelles riches. Les réseaux récurrents, les LSTM, les méthodes d'ensemble et les architectures profondes multi-horizons figurent parmi les familles mobilisées pour les séries temporelles (Lim & Zohren, 2021). Les revues de la littérature en finance soulignent à la fois l'essor de ces méthodes et l'hétérogénéité des données, des métriques et des protocoles de comparaison (Sezer et al., 2020).

Les résultats de cette littérature ne sont pas univoques. Un premier courant rapporte des gains de précision : sur les séries boursières (Fischer & Krauss, 2018) et sur la prévision des variations de bénéfices à partir de données comptables détaillées (Chen et al., 2022). Un second courant nuance ces résultats : les compétitions de prévision montrent que les méthodes d'apprentissage ne l'emportent pas systématiquement sur des méthodes statistiques simples (Makridakis et al., 2018) et que les meilleures solutions combinent plusieurs approches et reposent sur une validation hors échantillon rigoureuse (Makridakis et al., 2022). Un troisième courant déplace l'attention de la précision vers les conditions organisationnelles de la valeur : la capacité d'IA suppose des infrastructures, des données, des compétences et des mécanismes de coordination mobilisés conjointement (Mikalef & Gupta, 2021). Il en résulte une lacune : ces travaux évaluent soit la performance technique d'un modèle, soit la valeur organisationnelle d'une capacité, mais ils relient rarement l'usage de l'IA dans la prévision à la manière dont les utilisateurs jugent cette prévision, puis à leurs décisions.

Dans cette recherche, le construit UIA désigne l'« usage de l'IA dans la prévision financière ». Il renvoie à l'intensité, à la régularité et à l'intégration effective d'outils d'IA ou d'analyse prédictive dans les activités de budget, de trésorerie, de planification et de scénarisation. Il se distingue de l'adoption (présence ou non d'un outil) et de la capacité d'IA (ensemble de ressources, au sens de Mikalef et Gupta, 2021) : les items ont été adaptés de ces travaux, mais le construit mesure un usage perçu et non une capacité. Il ne mesure ni une famille algorithmique particulière ni le niveau de sophistication mathématique du modèle.

2.3. Qualité des données et qualité perçue des prévisions

La qualité des données est une condition préalable de toute activité de prévision. Wang et Strong (1996) distinguent les dimensions intrinsèque, contextuelle, représentationnelle et d'accessibilité de la qualité : une donnée peut être exacte mais trop ancienne, incomplète ou difficilement comparable pour soutenir une prévision. Les modèles de succès des systèmes d'information placent la qualité de l'information parmi les déterminants de l'usage, de la satisfaction et des bénéfices nets (DeLone & McLean, 2003 ; Wixom & Todd, 2005). Dans les environnements décisionnels, Işık et al. (2013) montrent que la qualité des données et l'intégration des systèmes sont des capacités importantes du succès des systèmes de Business Intelligence. La gouvernance des données, entendue comme l'ensemble des règles, des responsabilités et des processus qui assurent la qualité et l'usage approprié des données, est elle-même présentée comme un cadre organisationnel nécessaire à cette qualité (Abraham et al., 2019). Pour l'IA, la question est d'autant plus sensible que les erreurs, les ruptures de séries ou les incohérences peuvent être apprises et amplifiées par le modèle. Des données complètes, cohérentes et actualisées devraient donc accroître la fiabilité perçue des prévisions, leur pertinence et leur capacité d'anticipation.

H1 : La qualité des données est positivement associée à la qualité perçue des prévisions financières.

2.4. Usage de l'IA et qualité perçue des prévisions

Les outils d'IA peuvent améliorer une prévision de plusieurs manières : traitement automatisé de grands volumes d'information, repérage de relations non linéaires, actualisation plus fréquente des estimations, génération de scénarios et détection de signaux difficiles à traiter manuellement. Ces mécanismes sont cohérents avec les gains de précision observés dans certains contextes (Fischer & Krauss, 2018 ; Chen et al., 2022). L'étude ne teste toutefois pas la précision mathématique d'un modèle particulier : elle s'intéresse à la qualité perçue par les professionnels (précision, fiabilité, rapidité, pertinence, capacité d'anticipation et interprétabilité), car une prévision n'est mobilisée que si ses utilisateurs la jugent utile à leur processus de décision (Popovič et al., 2012). Le lien entre usage et qualité perçue n'est cependant pas automatique : la défiance à l'égard des algorithmes (Dietvorst et al., 2015) ou leur survalorisation (Logg et al., 2019) peuvent affecter le jugement porté sur leurs sorties. Une association positive est néanmoins attendue, un usage plus intense et mieux intégré permettant aux utilisateurs de mieux connaître les forces et les limites des prévisions produites.

H2 : L'usage de l'IA dans la prévision financière est positivement associé à la qualité perçue des prévisions financières.

2.5. Qualité perçue des prévisions et qualité de la décision stratégique

Une décision stratégique est ici entendue, à la suite de Dean et Sharfman (1996), comme une décision importante par les ressources qu'elle engage, dont l'efficacité dépend notamment de la qualité du processus décisionnel. Sa qualité suppose une réduction de l'incertitude, une meilleure comparaison des scénarios, une allocation plus cohérente des ressources et une capacité d'anticipation des risques. Les systèmes décisionnels ont précisément pour fonction d'améliorer le lien entre information et action : le modèle de DeLone et McLean (2003) conçoit les bénéfices nets comme l'aboutissement de la qualité du système et de l'information, et les travaux sur la Business Intelligence relient la maturité informationnelle à l'usage analytique des informations dans la décision (Popovič et al., 2012). À l'ère de l'IA, la structure des décisions organisationnelles dépend en outre de la répartition des tâches entre humains et algorithmes (Shrestha et al., 2019). La prévision financière constitue, dans cette perspective, un artefact intermédiaire : si les anticipations disponibles sont jugées plus fiables et plus pertinentes, elles peuvent renforcer la confiance du décideur et la qualité de l'arbitrage. Une association positive est donc attendue.

H3 : La qualité perçue des prévisions financières est positivement associée à la qualité de la décision stratégique.

2.6. Effet direct de l'usage de l'IA et effet indirect par la qualité perçue des prévisions

L'usage de l'IA peut également être associé directement à la qualité de la décision. Les outils analytiques permettent d'automatiser des analyses, d'explorer plus rapidement des alternatives, d'alerter sur des anomalies et de structurer l'accès à l'information, mécanismes que les recherches sur les capacités analytiques associent à l'agilité et à la performance organisationnelles (Gupta & George, 2016 ; Wamba et al., 2017). Ces mécanismes (détection d'anomalies, simulation, synthèse d'information) ne sont pas mesurés dans cette étude : ils fournissent une justification théorique de l'effet direct, non un résultat testé. L'effet direct attendu ne signifie pas que l'algorithme remplace le décideur ; il correspond à un enrichissement de son environnement informationnel, cohérent avec une logique d'augmentation du jugement humain (Raisch & Krakowski, 2021).

H4 : L'usage de l'IA dans la prévision financière est positivement associé à la qualité de la décision stratégique.

La cinquième hypothèse ne constitue pas une hypothèse indépendante : elle découle de la combinaison de H2 et de H3 et teste l'effet indirect de l'usage de l'IA sur la décision par


l'intermédiaire de la qualité perçue des prévisions. L'argument est que l'IA est associée à une meilleure décision en partie parce qu'elle produit ou facilite des prévisions que les professionnels jugent plus fiables, plus pertinentes et plus utiles. Le maintien d'un effet direct est théoriquement plausible, l'IA pouvant aider à la décision par d'autres voies que la prévision.

H5 : La qualité perçue des prévisions financières médiatise statistiquement la relation entre l'usage de l'IA dans la prévision financière et la qualité de la décision stratégique (effet indirect positif).

2.7. Modèle conceptuel et choix de spécification

Le modèle (Figure 1) comprend quatre construits et quatre chemins directs, ainsi que l'effet indirect de l'usage de l'IA sur la décision. Plusieurs chemins n'ont pas été retenus. Le chemin direct de la qualité des données vers la décision, et l'effet indirect qui en résulte, ne sont pas spécifiés dans le modèle de départ : l'argument théorique situe l'influence de la qualité des données sur la décision dans la qualité de la prévision, mais cette restriction est discutable et constitue une limite. De même, la qualité des données pourrait conditionner l'efficacité de l'IA (modération de l'effet de l'usage de l'IA par la qualité des données) ou précéder l'usage de l'IA ; ces spécifications, cohérentes avec la phase exploratoire, n'ont pas été testées ici et sont renvoyées aux perspectives. Les caractéristiques de l'entreprise et du répondant (taille, secteur, ancienneté d'usage de l'IA, fonction) ont été collectées, mais ne sont pas modélisées comme variables de contrôle. Le contexte institutionnel marocain (maturité numérique, compétences disponibles, cadre de protection des données) n'est pas théorisé dans le modèle ; il est pris en compte dans la discussion.

Figure 1 : Modèle conceptuel et hypothèses de recherche



Source : élaboration des auteurs. Note : les signes attendus sont indiqués entre parenthèses ; UIA : usage de l'IA dans la prévision financière ; QD : qualité des données ; QP : qualité perçue des prévisions ; DQ : qualité décisionnelle perçue.

3. Méthodologie de recherche

3.1. Positionnement et design de recherche

La recherche s'inscrit dans une posture post-positiviste et une logique hypothético-déductive. Elle mobilise un design mixte imbriqué (embedded) à dominante quantitative (Creswell & Plano Clark, 2018) : le volet quantitatif, fondé sur une enquête par questionnaire, teste les hypothèses ; un volet qualitatif exploratoire, réalisé en amont, joue un rôle contextuel et complémentaire. Les entretiens n'ont servi ni à construire l'instrument de mesure, dont les items sont adaptés de la littérature, ni à générer les hypothèses, formulées à partir de la revue de

littérature, et ils ne se substituent pas au test statistique. L'intégration des deux matériaux est opérée au moyen d'un tableau d'intégration (joint display ; Fetters et al., 2013), présenté en section 4.7.

Le modèle quantitatif comprend quatre construits réflectifs (mode A) : usage de l'IA dans la prévision financière (UIA), qualité des données (QD), qualité perçue des prévisions (QP) et qualité décisionnelle perçue (DQ). La spécification structurelle teste les chemins de QD vers QP, de UIA vers QP, de QP vers DQ et de UIA vers DQ, ainsi que l'effet indirect de UIA vers DQ par l'intermédiaire de QP.

3.2. Phase qualitative exploratoire

La phase exploratoire repose sur dix entretiens exploitables auprès de professionnels participant aux activités financières, budgétaires, analytiques ou décisionnelles. La sélection a recherché une diversité de fonctions, de secteurs et de tailles d'entreprise : directeurs administratifs et financiers (DAF), contrôleurs de gestion, analystes ou profils data, un trésorier, un comptable et un dirigeant de PME. Les entretiens ont duré de 29 à 45 minutes (moyenne : 38,4 minutes). L'analyse porte sur des synthèses détaillées de ces entretiens et a été conduite selon une démarche d'analyse thématique (Braun & Clarke, 2006), organisée autour des axes du modèle : usages de l'IA, qualité et gouvernance des données, effets sur la prévision, conséquences décisionnelles, supervision humaine et conditions de déploiement. Les résultats sont présentés sous forme de thèmes et d'effectifs bruts et servent à contextualiser l'interprétation des réponses quantitatives.

3.3. Instrument de mesure

Le questionnaire comprend vingt-trois indicateurs mesurés sur une échelle de Likert en sept points. Six items mesurent l'usage de l'IA dans la prévision financière, cinq la qualité des données, six la qualité perçue des prévisions et six la qualité décisionnelle perçue. Les formulations ont été adaptées au contexte de la prévision financière à partir des travaux sur les capacités et usages analytiques (Mikalef & Gupta, 2021 ; Visinescu et al., 2017), la qualité de l'information (Wixom & Todd, 2005), la qualité perçue des prévisions de trésorerie (Glaum et al., 2016) et la qualité de la décision (Visinescu et al., 2017 ; Abdellatif et al., 2024). Les items ont été adaptés en français et ne constituent pas la reprise littérale d'une échelle unique (Tableau 1). La qualité des mesures est appréciée à partir des diagnostics du modèle de mesure : fiabilité interne, validité convergente et validité discriminante (section 4.3).

Tableau 1 : Opérationnalisation synthétique des construits

Construit	Codes	Dimensions couvertes	Items	Sources d'adaptation
Usage de l'IA (UIA)	UIA1 à UIA6	Régularité, portée analytique, intégration, usage effectif, étendue, scénarisation	6	Mikalef & Gupta (2021) ; Visinescu et al. (2017)
Qualité des données (QD)	QD1 à QD5	Exactitude, complétude, actualité, niveau de détail, cohérence	5	Wixom & Todd (2005)
Qualité perçue des prévisions (QP)	QP1 à QP6	Fiabilité, précision perçue, rapidité, pertinence, anticipation, interprétabilité	6	Glaum et al. (2016)
Qualité décisionnelle perçue (DQ)	DQ1 à DQ6	Information, comparaison des options, rapidité, maîtrise de l'incertitude, confiance, alignement	6	Visinescu et al. (2017) ; Abdellatif et al. (2024)

Source : élaboration des auteurs à partir du protocole de recherche et des sources citées.

3.4. Population, échantillonnage et collecte des données

La population visée est constituée de professionnels travaillant dans des entreprises marocaines et disposant d'une connaissance effective des activités financières ou budgétaires et des outils numériques mobilisés par leur organisation. L'unité d'analyse est l'entreprise, représentée par un seul informateur clé, impliqué dans la préparation, l'interprétation ou la validation de

prévisions financières et/ou dans des décisions financières. L'entreprise devait utiliser depuis au moins six mois une fonction d'IA ou d'analyse prédictive, c'est-à-dire une fonction permettant de prévoir une évolution, de détecter une tendance ou une anomalie, de recommander une action ou de simuler des scénarios ; l'automatisation simple et l'usage d'un tableur sans fonction prédictive étaient exclus. L'éligibilité reposait sur la déclaration du répondant. Les participants ont été informés du caractère volontaire, anonyme et agrégé de l'étude et ont donné leur consentement.

La diffusion a été réalisée par échantillonnage raisonné (non probabiliste) et par réseaux professionnels. Au total, 270 questionnaires ont été examinés et vingt ont été exclus : six pour une ancienneté d'usage inférieure à six mois, six pour absence déclarée de fonction d'IA ou prédictive, deux parce que l'usage de l'IA n'était pas confirmé, quatre parce que le répondant n'était impliqué ni dans la prévision ni dans la décision, un pour plus de 30 % d'items manquants et un pour un profil de réponses invariant sur l'ensemble des échelles. Aucune imputation n'a été appliquée. L'échantillon final comprend 250 observations, collectées du 1er juin au 15 juillet 2026 ; la durée moyenne de réponse est de 11,4 minutes (médiane : 11,2 minutes). Le questionnaire étant anonyme, l'unicité des entreprises repose sur la consigne d'un seul informateur par organisation.

La taille de l'échantillon a été contrôlée de deux manières. Un calcul de puissance a priori, pour le scénario structurel le plus exigeant (deux prédicteurs pour un construit endogène), donne un minimum de 68 observations pour un effet moyen ($f^2 = 0,15$), un seuil $\alpha = 0,05$ et une puissance de 0,80 (Cohen, 1988 ; Faul et al., 2009). Une analyse de sensibilité indique qu'avec $n = 250$, l'effet minimal détectable est de l'ordre de $f^2 = 0,032$ pour le test d'un coefficient isolé (puissance de 0,80 ; $\alpha = 0,05$), valeur inférieure aux tailles d'effet observées (de 0,040 à 0,164). Par ailleurs, la méthode de la racine carrée inverse (Kock & Hadaya, 2018), appliquée au plus petit coefficient observé ($\beta = 0,197$), conduit à un minimum d'environ 160 observations, inférieur à l'échantillon disponible. Ces deux derniers calculs étant effectués à partir des coefficients estimés, ils ont une valeur indicative ; ils ne renseignent pas directement sur la puissance de détection de l'effet indirect.

Tableau 2 : Profil de l'échantillon quantitatif

Dimension	Modalité	n	%
Fonction	Contrôle de gestion	63	25,2
	Analyse / Data	44	17,6
	DAF / DF	43	17,2
	Comptabilité	37	14,8
	Trésorerie	31	12,4
	Direction générale	18	7,2
	Autre	14	5,6
Secteur	Services	69	27,6
	Industrie	56	22,4
	Commerce	44	17,6
	Finance	39	15,6
	Construction	31	12,4
	Autre	11	4,4
Taille	Moins de 10 salariés	31	12,4
	10 à 49 salariés	73	29,2
	50 à 249 salariés	85	34,0
	250 salariés ou plus	61	24,4
Ancienneté d'usage de l'IA	6 à 12 mois	73	29,2
	1 à 3 ans	106	42,4
	Plus de 3 ans	71	28,4

Source : enquête des auteurs, $n = 250$.

L'échantillon est diversifié sur le plan fonctionnel et sectoriel. Les contrôleurs de gestion représentent le premier groupe (25,2 %), suivis des profils analyse/data (17,6 %) et des DAF/DF (17,2 %). Les entreprises de 50 à 249 salariés constituent 34 % de l'échantillon et 58,4 % des répondants appartiennent à des entreprises d'au moins 50 salariés. Enfin, 70,8 % déclarent au moins une année d'usage de l'IA. Par ailleurs, 27,2 % des répondants relèvent de la comptabilité ou de la trésorerie et 7,2 % de la direction générale, ce qui interroge leur légitimité à évaluer la qualité de décisions stratégiques (section 5.7). Les solutions mobilisées se répartissent principalement entre ERP/BI (32,4 %), solutions spécialisées (25,6 %), outils internes (20 %), Python/R (14 %) et autres solutions (8 %). Dans la catégorie ERP/BI, seules les solutions comportant une fonctionnalité prédictive, de détection d'anomalies, de recommandation ou de scénarisation entraînent dans le périmètre de l'étude ; un ERP ou un outil BI utilisé uniquement à des fins descriptives n'était pas assimilé à de l'IA.

3.5. Contrôle du biais de méthode commune

Compte tenu du caractère auto-administré et mono-source de l'enquête, le risque de biais de méthode commune a été pris en compte. Des précautions procédurales ont été intégrées au questionnaire : anonymat des réponses, participation volontaire, définition opérationnelle de l'IA, filtrage d'éligibilité et organisation des mesures en blocs distincts. En complément, un diagnostic unifactoriel non roté portant sur les 23 items a été calculé. Ce diagnostic, reconnu comme peu sensible (Podsakoff et al., 2003, 2012), est utilisé comme contrôle complémentaire et non comme preuve suffisante d'absence de biais. Les limites de cette approche sont discutées en section 5.7.

3.6. Stratégie d'analyse PLS-SEM

Le PLS-SEM a été retenu parce que l'étude poursuit à la fois un objectif explicatif et un objectif de prédiction hors échantillon, avec un modèle comprenant un mécanisme de médiation et plusieurs construits latents (Hair et al., 2019 ; Shmueli et al., 2019). Pour des construits tous réfléchitifs, une estimation fondée sur les covariances (CB-SEM) ou le PLS consistant constitue toutefois une alternative légitime (Rönkkö & Evermann, 2013) ; cette alternative n'a pas été mise en œuvre ici (section 5.7). Les analyses ont été conduites sous SmartPLS 4 (Ringle et al., 2024). L'algorithme PLS utilise le schéma de pondération par chemins, avec un maximum de 3 000 itérations et un critère d'arrêt de 10^{-7} . La significativité des coefficients est évaluée au moyen d'un bootstrap non paramétrique de 10 000 rééchantillonnages, avec test bilatéral au seuil de 5 % et intervalles de confiance percentile à 95 % (Hair et al., 2022).

Le modèle de mesure est évalué à partir des loadings, de l'alpha de Cronbach, de ρ_A , de la fiabilité composite ρ_C et de l'AVE. La validité discriminante est examinée au moyen du critère HTMT, complété par les critères de Fornell-Larcker et les cross-loadings (Fornell & Larcker, 1981 ; Henseler et al., 2015). Le modèle structurel est évalué au moyen des coefficients de chemin, du R^2 , du R^2 ajusté, du f^2 et des effets indirects. Les tailles d'effet sont interprétées selon les seuils de Cohen (1988) (0,02 ; 0,15 ; 0,35) et le pouvoir explicatif selon ceux de Hair et al. (2011) (R^2 de 0,25, 0,50 et 0,75 pour un pouvoir faible, modéré et substantiel). La médiation est appréciée à partir de la significativité des effets direct et indirect et classée selon la typologie de Zhao et al. (2010) et de Nitzl et al. (2016) ; la VAF est rapportée à titre indicatif. Enfin, la capacité prédictive hors échantillon est évaluée par PLSpredict (Shmueli et al., 2019) et par le Cross-Validated Predictive Ability Test, CVPAT (Liengaard et al., 2021 ; Sharma et al., 2023), avec une validation croisée en dix plis répétée dix fois et une comparaison à un modèle linéaire ainsi qu'à un benchmark fondé sur la moyenne des indicateurs.

4. Résultats

4.1. Résultats qualitatifs

Le thème « qualité et gouvernance des données » apparaît dans les dix synthèses d'entretiens. Les gains décisionnels observés et la nécessité d'une supervision humaine et d'une explicabilité apparaissent chacun dans six entretiens sur dix. Les compétences et l'accompagnement, ainsi que le déploiement progressif avec validation, sont relevés dans quatre entretiens, et les contraintes de ressources et d'accessibilité dans deux (Tableau 3). Ces effectifs ne sont pas des fréquences généralisables à la population : ils signalent des thèmes récurrents dans un corpus de dix entretiens.

Tableau 3 : Principaux thèmes de la phase qualitative

Thème	Nombre d'entretiens (sur 10)
Qualité et gouvernance des données	10
Gains décisionnels observés	6
Supervision humaine et explicabilité	6
Compétences et accompagnement	4
Déploiement progressif et validation	4
Ressources et accessibilité	2

Source : analyse thématique des dix synthèses d'entretiens.

La question ouverte administrée aux répondants au questionnaire prolonge ces constats. Les réponses les plus fréquentes concernent la coordination entre la DSI et la direction financière (10,8 %), le maintien d'un contrôle humain systématique (10,4 %), l'accompagnement lors du déploiement initial (10 %) et la qualité et l'actualisation des données, évoquées sous plusieurs formulations. La clarification de la responsabilité en cas d'erreur de prévision (9,2 %) et l'implication des contrôleurs de gestion dès la conception du modèle (7,2 %) complètent ce tableau. Aucune catégorie ne dépasse 11 % : cette dispersion traduit une convergence limitée des réponses. La coordination entre finance et DSI, absente des thèmes de la phase d'entretiens (Tableau 3), ne ressort que de cette question ouverte.

4.2. Statistiques descriptives

Tableau 4 : Statistiques descriptives et corrélations des scores composites

Construit	Moyenne	Écart-type	UIA	QD	QP	DQ
UIA	4,253	1,032	1,000	0,265	0,424	0,329
QD	4,600	1,095	0,265	1,000	0,355	0,167
QP	4,552	1,106	0,424	0,355	1,000	0,418
DQ	4,514	1,087	0,329	0,167	0,418	1,000

Source : calculs des auteurs à partir des 250 réponses. Échelle de 1 à 7.

Les quatre construits présentent des moyennes supérieures au point médian de l'échelle. Les corrélations bivariées sont positives mais modérées. La corrélation la plus élevée concerne UIA et QP ($r = 0,424$), suivie de QP et DQ ($r = 0,418$). Ces corrélations fournissent une première indication cohérente avec le modèle, mais elles ne suffisent pas à conclure sur les hypothèses, qui sont testées par les coefficients structurels et leurs intervalles bootstrap.

4.3. Évaluation du modèle de mesure

Le diagnostic unifactoriel non roté fait apparaître un premier facteur expliquant 32,6 % de la variance totale des 23 items. Cette proportion reste inférieure au seuil heuristique de 50 %. Combiné aux précautions procédurales, ce résultat ne suggère pas qu'un facteur de méthode unique domine les réponses ; il n'exclut toutefois pas les biais inhérents à des mesures auto-rapportées.

Tableau 5 : Fiabilité interne et validité convergente

Construit	Items	Alpha	rho_A	rho_C	AVE
UIA	6	0,874	0,888	0,904	0,612
QD	5	0,872	0,875	0,907	0,661
QP	6	0,895	0,896	0,920	0,657
DQ	6	0,889	0,891	0,915	0,643

Source : résultats PLS-SEM.

Les indicateurs de fiabilité dépassent les seuils usuels de 0,70 pour les quatre construits. Les AVE sont comprises entre 0,612 et 0,661, ce qui confirme la validité convergente. Les loadings externes se situent approximativement entre 0,735 et 0,849 et sont tous statistiquement significatifs. Les valeurs de rho_C demeurent inférieures à 0,95, ce qui ne suggère pas une redondance excessive des indicateurs.

Tableau 6 : Validité discriminante selon le critère HTMT

Paire de construits	HTMT	IC95 % inférieur	IC95 % supérieur
UIA et QD	0,304	0,176	0,433
UIA et QP	0,479	0,369	0,580
UIA et DQ	0,374	0,265	0,480
QD et QP	0,402	0,277	0,517
QD et DQ	0,190	0,106	0,316
QP et DQ	0,468	0,349	0,575

Source : résultats PLS-SEM, bootstrap.

Toutes les valeurs HTMT sont inférieures au seuil de 0,85 et leurs bornes supérieures d'intervalle de confiance restent inférieures à 0,90. Le critère de Fornell-Larcker conduit à la même conclusion : la racine carrée de l'AVE de chaque construit est supérieure à ses corrélations avec les autres construits. Enfin, les VIF externes et internes sont tous inférieurs à 3 ; les VIF du modèle interne varient de 1,079 à 1,232. La colinéarité ne constitue donc pas une menace pour l'estimation des relations structurelles.

4.4. Évaluation du modèle structurel et test des hypothèses

Les quatre relations directes sont positives et significatives (Tableau 7 et Figure 2) : H1 à H4 sont soutenues. L'usage de l'IA présente le coefficient le plus élevé vis-à-vis de la qualité perçue des prévisions ($\beta = 0,364$), devant la qualité des données ($\beta = 0,259$). La qualité perçue des prévisions est positivement associée à la qualité décisionnelle ($\beta = 0,334$), tandis que l'usage de l'IA conserve une association directe plus faible mais significative avec celle-ci ($\beta = 0,197$).

Tableau 7 : Coefficients structurels

Hyp.	Relation	β	t	p	IC95 %
H1	QD vers QP	0,259	4,58	< 0,001	[0,149 ; 0,370]
H2	UIA vers QP	0,364	7,02	< 0,001	[0,262 ; 0,464]
H3	QP vers DQ	0,334	5,35	< 0,001	[0,210 ; 0,454]
H4	UIA vers DQ	0,197	3,36	< 0,001	[0,084 ; 0,314]

Source : bootstrap non paramétrique, 10 000 rééchantillonnages.


Tableau 8 : Pouvoir explicatif et tailles d'effet

Construit endogène	R ²	R ² ajusté	IC95 % du R ²	Relation	f ²	Interprétation
QP	0,250	0,244	[0,173 ; 0,351]	UIA vers QP	0,164	Moyen
				QD vers QP	0,083	Faible
DQ	0,207	0,201	[0,135 ; 0,306]	QP vers DQ	0,114	Faible
				UIA vers DQ	0,040	Faible

Source : résultats PLS-SEM.

Le modèle explique 25,0 % de la variance de la qualité perçue des prévisions et 20,7 % de celle de la qualité décisionnelle perçue, ce qui laisse respectivement 75,0 % et 79,3 % de cette variance inexpliquée. Les intervalles bootstrap à 95 % sont [0,173 ; 0,351] et [0,135 ; 0,306]. Selon les seuils de Hair et al. (2011), le R^2 de QP se situe à la limite basse du pouvoir explicatif faible (0,25) et celui de DQ en dessous de cette limite. Les tailles d'effet, interprétées selon Cohen (1988), indiquent un effet moyen de UIA sur QP ($f^2 = 0,164$) et des effets faibles pour les autres relations. Ces niveaux sont cohérents avec un modèle parcimonieux portant sur des perceptions organisationnelles, où de nombreux autres facteurs non modélisés peuvent intervenir, mais ils invitent à ne pas surévaluer la portée explicative du modèle.

Figure 2 : Modèle structurel estimé (coefficients de chemin et R^2)



Source : résultats PLS-SEM, bootstrap non paramétrique (10 000 rééchantillonnages). Note : *** $p < 0,001$; le modèle estimé ne comporte pas de variables de contrôle.

4.5. Test de la médiation

L'effet indirect de l'usage de l'IA sur la qualité décisionnelle par l'intermédiaire de la qualité perçue des prévisions est positif et significatif (Tableau 9). L'effet direct demeure lui aussi significatif et de même signe. L'effet total atteint 0,319 (les valeurs étant calculées avant arrondi, la somme des effets arrondis peut différer d'un millièm) et la VAF indique que 38,1 % de cet effet total transite par le médiateur. Conformément à la typologie de Zhao et al. (2010) et de Nitzl et al. (2016), la configuration correspond à une médiation partielle complémentaire, puisque les effets direct et indirect sont significatifs et de même signe : H5 est soutenue. Compte tenu du plan transversal, il s'agit d'une médiation statistique et non de la démonstration d'un processus causal.

Tableau 9 : Effets direct, indirect et total de l'usage de l'IA sur la qualité décisionnelle

Effet	β	t	p	IC95 %
Effet direct (UIA vers DQ)	0,197	3,36	< 0,001	[0,084 ; 0,314]
Effet indirect (UIA vers DQ via QP)	0,121	4,21	< 0,001	[0,070 ; 0,183]
Effet total (UIA vers DQ)	0,319	n.r.	n.r.	n.r.

Source : bootstrap non paramétrique, 10 000 rééchantillonnages. VAF = 38,1 %. n.r. : non rapporté.

Pour la qualité des données, qui ne dispose d'aucun chemin direct vers la décision dans le modèle, l'effet indirect par l'intermédiaire de la qualité perçue des prévisions, calculé à titre indicatif comme le produit des coefficients de chemin ($0,259 \times 0,334$), est de l'ordre de 0,087.

4.6. Pertinence prédictive hors échantillon

L'évaluation PLSpredict complète l'interprétation explicative du modèle. Avec une validation croisée en dix plis répétée dix fois, les Q^2 predict sont positifs pour les douze indicateurs endogènes de QP et DQ, mais faibles (de 0,065 à 0,177), et le RMSE du modèle PLS-SEM est inférieur à celui du benchmark linéaire pour chacun des douze indicateurs. Le CVPAT au niveau des variables latentes indique une perte globale inférieure à celle du benchmark fondé sur la moyenne des indicateurs (différence moyenne de perte = -0,211 ; $t = 4,41$; $p < 0,001$) et à celle du modèle linéaire (différence = -0,068 ; $t = 3,17$; $p = 0,002$). L'écart avec le modèle linéaire est modeste : il est significatif pour QP ($p = 0,001$) mais pas séparément pour DQ ($p = 0,073$), de sorte que l'avantage prédictif est global plutôt qu'uniforme. Surtout, la prédiction porte sur des perceptions déclarées par un même répondant et non sur une erreur de prévision observée. Ces résultats évaluent donc la capacité prédictive du modèle perceptuel ; ils ne démontrent pas que les algorithmes employés par les entreprises produisent une erreur de prévision financière inférieure à celle des méthodes traditionnelles.

4.7. Intégration des résultats qualitatifs et quantitatifs

Le Tableau 10 met en regard les thèmes de la phase exploratoire et les résultats du modèle, afin d'indiquer où les deux matériaux convergent, divergent ou se complètent.

Tableau 10 : Tableau d'intégration des résultats qualitatifs et quantitatifs

Thème qualitatif	Résultat quantitatif correspondant	Lecture intégrée
Qualité et gouvernance des données (10 entretiens sur 10)	QD vers QP : $\beta = 0,259$; $f^2 = 0,083$ (faible) ; corrélation QD et DQ : $r = 0,167$	Divergence partielle : thème le plus fréquent mais association quantitative la plus faible ; chemin de QD vers DQ non testé
Gains décisionnels observés (6 entretiens sur 10)	QP vers DQ : $\beta = 0,334$; UIA vers DQ : $\beta = 0,197$; effet indirect : $\beta = 0,121$	Convergence : l'IA est associée à la décision directement et par la qualité perçue des prévisions
Supervision humaine et explicabilité (6 entretiens sur 10) ; contrôle humain systématique (question ouverte, 10,4 %)	Non mesurée dans le modèle ; l'interprétabilité n'intervient que comme dimension de QP	Complément : condition évoquée mais non testée, piste de modération
Compétences et accompagnement (4 entretiens sur 10) ; accompagnement du déploiement (question ouverte, 10 %)	Non mesurés dans le modèle	Complément : condition à mesurer dans de futurs travaux
Coordination entre finance et DSI (question ouverte, 10,8 % ; absente du Tableau 3)	Non mesurée dans le modèle	Complément issu de la seule question ouverte, sans appui dans les entretiens
Déploiement progressif et validation (4 entretiens sur 10)	Non mesuré dans le modèle	Complément : piste managériale à valider

Source : élaboration des auteurs à partir des Tableaux 3, 7 et 9 et de la question ouverte.

5. Discussion

5.1. De l'usage de l'IA à la qualité perçue des prévisions

L'association la plus élevée parmi celles testées concerne l'usage de l'IA et la qualité perçue des prévisions ($\beta = 0,364$; $f^2 = 0,164$, effet moyen). Ce résultat est cohérent avec les travaux montrant que les techniques d'apprentissage peuvent améliorer certaines tâches de prévision lorsqu'elles exploitent des relations complexes et de grands volumes d'information (Fischer & Krauss, 2018 ; Chen et al., 2022). Il doit toutefois être lu avec prudence : les répondants n'évaluent pas un concours d'algorithmes, ils jugent, dans leur environnement de travail, si les prévisions leur paraissent plus fiables, plus rapides et plus utiles. Cette mesure perceptuelle peut refléter la qualité des prévisions, mais aussi la familiarité avec l'outil ou une disposition

favorable à la technologie, deux explications que le plan de l'étude ne permet pas de départager (section 5.4). Le résultat est compatible avec une lecture en termes de capacités : une capacité d'IA repose sur une combinaison de technologies, de données, de compétences et de ressources organisationnelles (Mikalef & Gupta, 2021). Les entretiens vont dans le même sens, les difficultés évoquées concernant moins l'algorithme pris isolément que la supervision humaine et l'accompagnement des utilisateurs ; la coordination entre finance et DSI ressort, elle, de la question ouverte.

5.2. La qualité des données et la tension avec la phase qualitative

H1 est également soutenue : la qualité des données est positivement associée à la qualité perçue des prévisions ($\beta = 0,259$). L'association est inférieure à celle de l'usage de l'IA et sa taille est faible ($f^2 = 0,083$), mais elle est statistiquement robuste. Ce résultat converge avec Glaum et al. (2016), qui montrent que la perception de la qualité des prévisions de trésorerie dépend notamment de la qualité des données d'entrée et de l'efficacité du processus de prévision, ainsi qu'avec Işık et al. (2013) sur le rôle de la qualité des données dans le succès des environnements de Business Intelligence. L'étude étend ce constat à un échantillon multisectoriel d'entreprises marocaines utilisant des outils prédictifs.

Ce résultat appelle une discussion explicite de la triangulation. La qualité et la gouvernance des données apparaissent dans les dix entretiens, au premier rang des thèmes, alors que la qualité des données présente, dans le modèle, la plus faible association avec la qualité perçue des prévisions ($f^2 = 0,083$), la plus faible corrélation avec la qualité décisionnelle ($r = 0,167$) et aucun chemin direct testé vers la décision. Plusieurs lectures sont possibles. Les entretiens évoquent une gouvernance des données plus large que les cinq dimensions mesurées (exactitude, complétude, actualité, niveau de détail, cohérence). La qualité des données peut aussi agir comme une condition de l'efficacité de l'IA (effet modérateur) ou comme un antécédent de son usage, spécifications non testées ici. Enfin, dans des entreprises qui utilisent déjà des outils prédictifs depuis au moins six mois, la qualité des données peut être suffisante pour que son effet marginal soit modeste. Ces lectures appellent des tests dédiés (section 6). L'association observée, jointe aux entretiens, invite néanmoins à ne pas évaluer l'investissement dans l'IA indépendamment d'un programme de gouvernance des données : une entreprise qui automatise un processus de prévision sur des historiques incomplets ou des définitions comptables instables risque d'accélérer la production d'une prévision contestée.

5.3. La qualité perçue des prévisions comme relais statistique vers la décision

La qualité perçue des prévisions est positivement associée à la qualité décisionnelle ($\beta = 0,334$; $f^2 = 0,114$, effet faible) et l'effet indirect de l'usage de l'IA par l'intermédiaire de la qualité perçue des prévisions est significatif ($\beta = 0,121$). Avec une VAF de 38,1 %, une part substantielle mais non majoritaire de l'effet total statistique de l'usage de l'IA sur la décision passe par la qualité perçue des prévisions. Ce résultat reste compatible avec le modèle de succès des systèmes d'information, qui relie qualité de l'information, usage et bénéfices (DeLone & McLean, 2003), et avec les travaux sur la Business Intelligence qui associent maturité informationnelle et décision analytique (Popovič et al., 2012). Il prolonge Visinescu et al. (2017), qui associent l'usage de la Business Intelligence et la qualité de l'information à la qualité perçue des décisions, ainsi qu'Abdellatif et al. (2024), qui mettent en évidence le rôle de la rapidité et de la complétude de la décision dans les effets des capacités de business analytics. Le modèle ajoute un maillon propre à la finance, la qualité perçue des prévisions : la valeur décisionnelle associée à l'IA semble ainsi dépendre en partie de sa capacité à produire des anticipations que les utilisateurs jugent crédibles et exploitables.

L'association directe entre l'usage de l'IA et la décision reste significative ($\beta = 0,197$) : tout le lien ne passe donc pas par la prévision. L'automatisation de certains contrôles, la détection

d'anomalies, l'accès plus rapide à l'information ou la simulation peuvent intervenir, mais ces mécanismes ne sont pas mesurés ici. La médiation observée est partielle et complémentaire, ce qui est cohérent avec l'idée d'augmentation du jugement humain (Raisch & Krakowski, 2021) : l'IA soutient le système humain de décision davantage qu'elle ne le remplace.

5.4. Explications alternatives

Plusieurs explications alternatives doivent être discutées avant de retenir l'interprétation précédente. Premièrement, la causalité inverse : des décideurs satisfaits de leurs décisions peuvent juger plus favorablement les prévisions qui les ont soutenues, et des entreprises déjà performantes peuvent investir davantage dans l'IA. Deuxièmement, l'effet de halo : un même informateur évalue la qualité perçue des prévisions et celle de la décision, et un jugement global favorable peut contaminer les deux mesures et gonfler leur association. Troisièmement, les variables confondantes : la maturité numérique, la taille, le secteur et les compétences disponibles peuvent à la fois favoriser l'usage de l'IA et améliorer la qualité perçue des prévisions ; elles n'ont pas été contrôlées dans le modèle estimé. Quatrièmement, l'auto-sélection : les entreprises du champ de l'étude sont, par construction, utilisatrices d'IA depuis au moins six mois, et celles dont un représentant a répondu peuvent être plus favorables à l'IA que les autres. Le plan transversal ne permet pas d'écarter ces explications, ce qui invite à lire les coefficients comme des associations statistiques.

5.5. Spécificité et apport du contexte marocain

Dans le cas marocain, les travaux consacrés à l'IA appliquée aux problématiques financières des entreprises portent surtout sur la performance prédictive. Jamil et al. (2026a) montrent, à partir d'entreprises cotées, que certains modèles de machine learning peuvent dépasser des régressions classiques pour prédire la rentabilité, et Jamil et al. (2026b) rapportent que des architectures d'apprentissage profond surpassent des références naïves et linéaires pour prédire la création de valeur actionnariale sur le marché boursier marocain. La question posée ici est différente mais complémentaire : il ne s'agit pas d'identifier l'algorithme qui prévoit le mieux un indicateur observé, mais d'examiner comment l'usage d'outils d'IA est associé, dans le travail des professionnels, à des prévisions jugées de meilleure qualité puis à des décisions jugées plus solides.

L'échantillon réunit 250 observations d'entreprises marocaines de tailles et de secteurs variés, chacune représentée par un informateur clé impliqué dans les processus financiers ou décisionnels. Cette composition élargit l'analyse au-delà des seules entreprises cotées. Elle montre aussi que l'usage étudié n'est pas uniquement expérimental : 70,8 % des répondants déclarent au moins une année d'utilisation de l'IA, dans un contexte où l'IA est un axe affiché des stratégies nationales (Hespress, 2024 ; Ministère de la Transition numérique et de la Réforme de l'administration, 2026). Dans ce terrain, la question n'est donc plus seulement celle de l'adoption ; elle concerne l'intégration des outils, la gouvernance des données et l'évaluation de leur utilité. Cette spécificité reste toutefois peu exploitée : les données permettraient des comparaisons selon la taille, le secteur et l'ancienneté d'usage, qui ne sont pas conduites ici, et aucune comparaison systématique des tailles d'effet avec celles d'études menées en contexte émergent ou africain n'est proposée. Ces analyses constituent une piste de recherche prioritaire (section 6).

5.6. Contributions théoriques et implications managériales

L'apport théorique tient au rôle donné à la qualité perçue des prévisions. En spécifiant, pour la prévision financière assistée par l'IA, la chaîne « qualité de l'information, usage, bénéfices » du modèle de succès des systèmes d'information (DeLone & McLean, 2003), l'étude montre qu'une partie de la valeur décisionnelle associée à l'IA apparaît lorsque le résultat analytique devient une information prévisionnelle jugée crédible par l'utilisateur. Cette contribution reste

modeste : le modèle reprend la structure du cadre dont il s'inspire, la qualité perçue des prévisions n'explique qu'une part limitée de la variance de la décision ($R^2 = 0,207$) et la médiation est statistique.

Sur le plan managérial, il convient de distinguer ce qui découle des résultats quantitatifs et ce qui relève de pistes issues de la phase exploratoire. Les résultats quantitatifs suggèrent que l'introduction d'un outil d'IA ne suffit pas : l'usage de l'IA et la qualité des données sont associés à la qualité perçue des prévisions, laquelle est associée à la qualité des décisions. Les quatre conditions suivantes proviennent en revanche des entretiens et de la question ouverte, et n'ont pas été testées dans le modèle : la gouvernance des données (dictionnaires, règles de qualité, responsabilités, historisation, cohérence entre systèmes), le travail conjoint de la fonction financière et de la DSI, la supervision humaine (procédures de validation, d'explication et de traçabilité) et les compétences d'interprétation des prévisions. Elles doivent être lues comme des pistes à mesurer dans de futurs travaux. De même, la recommandation d'un déploiement progressif (commencer par un domaine aux données suffisamment structurées, comme la trésorerie, les ventes, le besoin en fonds de roulement ou le budget, puis comparer la prévision assistée par l'IA à la référence habituelle et documenter les écarts) ne s'appuie que sur quatre entretiens sur dix : elle relève de la prudence managériale plus que d'un résultat démontré. L'indicateur de succès pertinent n'est pas le nombre de modèles déployés mais l'amélioration du travail de prévision et de la décision qu'ils sont censés soutenir.

5.7. Limites de l'étude

Les limites sont présentées de la plus à la moins sévère pour la validité des conclusions, avec les mesures prévues ou envisagées pour en atténuer l'effet.

Validité des mesures. Les items ont été adaptés et traduits à partir d'échelles antérieures, mais une validation de contenu par experts (indice de validité de contenu, Lawshe, 1975), une rétrotraduction et un prétest pilote distinct ne sont pas documentés. La validation des construits repose donc sur les diagnostics psychométriques a posteriori, qui ne remplacent pas ces étapes. De plus, les dimensions couvertes par QD et QP renvoient à des facettes conceptuellement distinctes, ce qui interroge la spécification réflective (Jarvis et al., 2003), et des recouvrements existent entre QP et DQ (rapidité, incertitude). Une analyse tétrade confirmatoire (Gudergan et al., 2008) ou une modélisation d'ordre supérieur n'a pas été conduite. Le construit DQ renvoie par ailleurs à une qualité décisionnelle générale perçue plus qu'à des décisions stratégiques particulières. Une validation par experts et un prétest cognitif sont prévus avant toute extension de l'enquête, ainsi que le test de spécifications alternatives.

Base qualitative. L'analyse qualitative repose sur dix synthèses d'entretiens et non sur des transcriptions intégrales ; le guide d'entretien, la procédure de codage et la fiabilité inter-codeurs ne sont pas documentés dans cet article, et ce nombre d'entretiens ne permet pas de revendiquer la saturation (Guest et al., 2006). Cette phase est donc ramenée à un rôle de cadrage, ses résultats ne sont pas généralisables et les affirmations qui en découlent ont été atténuées.

Échantillonnage. L'échantillon est non probabiliste et issu de réseaux professionnels, ce qui peut induire une homogénéité des profils et limite la généralisation. Le taux de réponse, la répartition géographique et la comparaison avec la population des entreprises marocaines ne sont pas rapportés, et aucun test de biais de non-réponse (Armstrong & Overton, 1977) n'est présenté. L'unicité des entreprises repose sur la consigne d'un seul informateur par organisation. Le champ de l'étude, restreint aux entreprises utilisant l'IA depuis au moins six mois sur déclaration du répondant, exclut les non-utilisateurs et peut réduire la variance de la variable explicative, ce qui peut atténuer les relations observées ; les résultats ne portent donc que sur des entreprises utilisatrices. Enfin, 27,2 % des répondants relèvent de la comptabilité ou de la trésorerie et 7,2 % de la direction générale : leur légitimité à évaluer la qualité de

décisions stratégiques est discutable, et une analyse de sensibilité selon les fonctions (DAF, direction générale, contrôle de gestion) n'est pas rapportée.

Biais de méthode commune et effet de halo. La qualité perçue des prévisions et la qualité décisionnelle sont deux perceptions déclarées par le même informateur. Le test de Harman, peu sensible, est le seul diagnostic statistique rapporté et les précautions procédurales (blocs distincts) restent faibles. Une évaluation de la colinéarité totale (Kock, 2015), une variable marqueur ou un contrôle de désirabilité sociale ne sont pas mis en œuvre ; un effet de halo entre QP et DQ ne peut être écarté.

Modèle et estimation. Le modèle estimé comporte quatre chemins, sans variables de contrôle ; les spécifications concurrentes (chemin de QD vers DQ, modulation de l'effet de UIA par QD, chemin de QD vers UIA) ne sont pas comparées. Le pouvoir explicatif est limité (R^2 de 0,250 et 0,207). Pour des construits réflectifs, une estimation par CB-SEM ou par PLS consistant aurait pu être retenue (Rönkkö & Evermann, 2013) ; l'indice SRMR, un test d'endogénéité (copule gaussienne ; Hult et al., 2018) et des analyses d'hétérogénéité (MICOM, analyses multi-groupes selon la taille ou le secteur) ne sont pas rapportés. Les loadings par item, la matrice de Fornell-Larcker, les cross-loadings, les statistiques descriptives par item et les paramètres de reproductibilité (graine aléatoire, intervalles BCa) ne sont pas présentés dans cet article.

Mesure perceptuelle et plan transversal. L'étude mesure une qualité perçue des prévisions et non l'erreur de prévision réelle (MAPE, RMSE) d'outils d'IA précis, et ne compare pas ces outils entre eux. Le plan transversal interdit en outre toute inférence causale. Ces deux limites sont reprises dans les perspectives de recherche de la conclusion.

6. Conclusion

Cette étude cherchait à savoir dans quelle mesure l'usage de l'IA dans la prévision financière et la qualité des données sont associés à la qualité perçue des prévisions, et celle-ci à la qualité des décisions stratégiques d'entreprises marocaines. Dans l'échantillon de 250 entreprises utilisatrices d'IA, l'usage de l'IA ($\beta = 0,364$) et la qualité des données ($\beta = 0,259$) sont positivement associés à la qualité perçue des prévisions, laquelle est positivement associée à la qualité décisionnelle perçue ($\beta = 0,334$). L'usage de l'IA reste directement associé à la décision ($\beta = 0,197$), et l'effet indirect statistique par la qualité perçue des prévisions ($\beta = 0,121$) correspond à une médiation partielle complémentaire. Ces associations sont de force modérée à faible : le modèle explique 25,0 % et 20,7 % de la variance des deux construits endogènes.

Sur le plan théorique, l'étude spécifie, pour la prévision financière assistée par l'IA, la chaîne « information, usage, bénéfices » du modèle de succès des systèmes d'information, en plaçant la qualité perçue des prévisions comme mécanisme statistique de transmission et en la situant à l'articulation de la littérature sur les capacités d'IA et de celle sur l'interaction entre humains et algorithmes. L'apport reste incrémental et appelle des tests sur des données longitudinales.

Pour les dirigeants et les professionnels de la finance, le résultat central est qu'introduire un outil d'IA ne suffit pas : il importe que les prévisions produites soient jugées crédibles, rapides, pertinentes et exploitables dans le processus de décision. La phase exploratoire, dont les enseignements ne sont pas testés dans le modèle, désigne la gouvernance des données, la coordination entre finance et DSI, la supervision humaine et l'accompagnement des utilisateurs comme des conditions à instruire. Pour les régulateurs et les pouvoirs publics engagés dans les stratégies Digital Morocco 2030 et Maroc IA 2030, ces résultats suggèrent d'accompagner la diffusion des outils par des actions sur les compétences et sur la qualité des données.

Les principales limites tiennent au plan transversal, aux mesures perceptuelles, à la validation incomplète des items, à une base qualitative réduite à dix synthèses, à l'échantillonnage non probabiliste et au risque de biais de méthode commune (section 5.7). Plusieurs protocoles permettraient de les lever : un panel à deux vagues de mesure pour distinguer l'antériorité temporelle de l'usage de l'IA, de la qualité perçue et de la décision ; une étude comparant

l'erreur de prévision observée (MAPE, RMSE) à la qualité perçue dans les mêmes entreprises, avec ou sans assistance algorithmique ; des tests de modération de l'effet de l'usage de l'IA par la gouvernance des données et par la supervision humaine ; des enquêtes multi-informants associant directeurs financiers et direction générale ; des analyses multi-groupes selon la taille, le secteur et l'ancienneté d'usage ; enfin des comparaisons avec d'autres pays du Maghreb ou d'Afrique et des travaux sur l'IA générative dans l'analyse financière.

Références

- (1). Abdellatif, M. A. M., Abubakar, A. M., Elayan, M. B. H., & Hayajneh, J. A. M. (2024). Business analytics capabilities and decision quality: The mediating roles of decision speed and comprehensiveness. *Information Systems Management*, 41(1), 91–108. <https://doi.org/10.1080/10580530.2023.2179704>
- (2). Abraham, R., Schneider, J., & vom Brocke, J. (2019). Data governance: A conceptual framework, structured review, and research agenda. *International Journal of Information Management*, 49, 424–438. <https://doi.org/10.1016/j.ijinfomgt.2019.07.008>
- (3). Armstrong, J. S., & Overton, T. S. (1977). Estimating nonresponse bias in mail surveys. *Journal of Marketing Research*, 14(3), 396–402. <https://doi.org/10.1177/002224377701400320>
- (4). Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77–101. <https://doi.org/10.1191/1478088706qp063oa>
- (5). Chen, X., Cho, Y. H., Dou, Y., & Lev, B. (2022). Predicting future earnings changes using machine learning and detailed financial data. *Journal of Accounting Research*, 60(2), 467–515. <https://doi.org/10.1111/1475-679X.12429>
- (6). Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2^e éd.). Lawrence Erlbaum Associates.
- (7). Concentrix, & Ipsos. (2026, 8 avril). *Concentrix lance le premier Observatoire de l'expérience client à l'ère de l'IA au Maroc en partenariat* [Communiqué de presse]. Hespress. <https://fr.hespress.com/468751-concentrix-lance-le-premier-observatoire-de-l-experience-client-a-lere-de-lia-au-maroc-en-partenariat.html>
- (8). Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (3^e éd.). SAGE Publications.
- (9). Dean, J. W., & Sharfman, M. P. (1996). Does decision process matter? A study of strategic decision-making effectiveness. *Academy of Management Journal*, 39(2), 368–396. <https://doi.org/10.5465/256784>
- (10). DeLone, W. H., & McLean, E. R. (2003). The DeLone and McLean model of information systems success: A ten-year update. *Journal of Management Information Systems*, 19(4), 9–30. <https://doi.org/10.1080/07421222.2003.11045748>
- (11). Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114–126. <https://doi.org/10.1037/xge0000033>
- (12). Faul, F., Erdfelder, E., Buchner, A., & Lang, A.-G. (2009). Statistical power analyses using G*Power 3.1: Tests for correlation and regression analyses. *Behavior Research Methods*, 41(4), 1149–1160. <https://doi.org/10.3758/BRM.41.4.1149>
- (13). Fetters, M. D., Curry, L. A., & Creswell, J. W. (2013). Achieving integration in mixed methods designs: Principles and practices. *Health Services Research*, 48(6 Pt. 2), 2134–2156. <https://doi.org/10.1111/1475-6773.12117>

- (14). Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- (15). Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.1177/002224378101800104>
- (16). Glaum, M., Schmidt, P., & Schnürer, K. (2016). What determines managers' perceptions of cash flow forecasting quality? Evidence from a multinational corporation. *Journal of International Financial Management & Accounting*, 27(3), 298–346. <https://doi.org/10.1111/jifm.12045>
- (17). Goodhue, D. L., & Thompson, R. L. (1995). Task-technology fit and individual performance. *MIS Quarterly*, 19(2), 213–236. <https://doi.org/10.2307/249689>
- (18). Gudergan, S. P., Ringle, C. M., Wende, S., & Will, A. (2008). Confirmatory tetrad analysis in PLS path modeling. *Journal of Business Research*, 61(12), 1238–1249. <https://doi.org/10.1016/j.jbusres.2008.01.012>
- (19). Guest, G., Bunce, A., & Johnson, L. (2006). How many interviews are enough? An experiment with data saturation and variability. *Field Methods*, 18(1), 59–82. <https://doi.org/10.1177/1525822X05279903>
- (20). Gupta, M., & George, J. F. (2016). Toward the development of a big data analytics capability. *Information & Management*, 53(8), 1049–1064. <https://doi.org/10.1016/j.im.2016.07.004>
- (21). Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A primer on partial least squares structural equation modeling (PLS-SEM)* (3^e éd.). Sage Publications.
- (22). Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139–152. <https://doi.org/10.2753/MTP1069-6679190202>
- (23). Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- (24). Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- (25). Hespress. (2024, 25 septembre). *Digital Morocco 2030 : 100 milliards de dirhams et 240.000 emplois pour dynamiser l'économie numérique*. <https://fr.hespress.com/387500-digital-morocco-2030-100-milliards-de-dirhams-et-240-000-emplois-pour-dynamiser-leconomie-numerique.html>
- (26). Hult, G. T. M., Hair, J. F., Proksch, D., Sarstedt, M., Pinkwart, A., & Ringle, C. M. (2018). Addressing endogeneity in international marketing applications of partial least squares structural equation modeling. *Journal of International Marketing*, 26(3), 1–21. <https://doi.org/10.1509/jim.17.0151>
- (27). Işık, Ö., Jones, M. C., & Sidorova, A. (2013). Business intelligence success: The roles of BI capabilities and decision environments. *Information & Management*, 50(1), 13–23. <https://doi.org/10.1016/j.im.2012.12.001>
- (28). Jamil, Y., El Yamlaoui, I., & Bouayad Amine, N. (2026a). Predicting corporate profitability in Morocco: Comparing classical regression and machine learning. *Qubahan Academic Journal*, 6(1), 164–193. <https://doi.org/10.48161/qaj.v6n1a1972>
- (29). Jamil, Y., El Yamlaoui, I., & Bouayad Amine, N. (2026b). Sequential deep learning for predicting shareholder value creation: Evidence from the Moroccan stock market.

- Journal of Risk and Financial Management*, 19(7), Article 493.
<https://doi.org/10.3390/jrfm19070493>
- (30). Jarvis, C. B., MacKenzie, S. B., & Podsakoff, P. M. (2003). A critical review of construct indicators and measurement model misspecification in marketing and consumer research. *Journal of Consumer Research*, 30(2), 199–218.
<https://doi.org/10.1086/376806>
 - (31). Jöhnik, J., Weißert, M., & Wyrski, K. (2021). Ready or not, AI comes: An interview study of organizational AI readiness factors. *Business & Information Systems Engineering*, 63(1), 5–20. <https://doi.org/10.1007/s12599-020-00676-7>
 - (32). Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
 - (33). Kock, N. (2015). Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of e-Collaboration*, 11(4), 1–10.
<https://doi.org/10.4018/ijec.2015100101>
 - (34). Kock, N., & Hadaya, P. (2018). Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. *Information Systems Journal*, 28(1), 227–261. <https://doi.org/10.1111/isj.12131>
 - (35). Lawshe, C. H. (1975). A quantitative approach to content validity. *Personnel Psychology*, 28(4), 563–575. <https://doi.org/10.1111/j.1744-6570.1975.tb01393.x>
 - (36). Liengaard, B. D., Sharma, P. N., Hult, G. T. M., Jensen, M. B., Sarstedt, M., Hair, J. F., & Ringle, C. M. (2021). Prediction: Coveted, yet forsaken? Introducing a cross-validated predictive ability test in partial least squares path modeling. *Decision Sciences*, 52(2), 362–392. <https://doi.org/10.1111/deci.12445>
 - (37). Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), Article 20200209.
<https://doi.org/10.1098/rsta.2020.0209>
 - (38). Logg, J. M., Minson, J. A., & Moore, D. A. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90–103. <https://doi.org/10.1016/j.obhdp.2018.12.005>
 - (39). Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3), Article e0194889. <https://doi.org/10.1371/journal.pone.0194889>
 - (40). Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
 - (41). Mikalef, P., & Gupta, M. (2021). Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. *Information & Management*, 58(3), Article 103434.
<https://doi.org/10.1016/j.im.2021.103434>
 - (42). Ministère de la Transition numérique et de la Réforme de l'administration. (2026, 8 septembre). *Les principales avancées de la feuille de route « Maroc IA 2030 » présentées à Rabat*. Portail national maroc.ma. <https://maroc.ma/fr/actualites/les-principales-avancees-de-la-feuille-de-route-maroc-ia-2030-presentees-rabat>
 - (43). Nitzl, C., Roldán, J. L., & Cepeda, G. (2016). Mediation analysis in partial least squares path modeling: Helping researchers discuss more sophisticated models. *Industrial Management & Data Systems*, 116(9), 1849–1864. <https://doi.org/10.1108/IMDS-07-2015-0302>

- (44). Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., ... Ziel, F. (2022). Forecasting: Theory and practice. *International Journal of Forecasting*, 38(3), 705–871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- (45). Podsakoff, P. M., MacKenzie, S. B., Lee, J.-Y., & Podsakoff, N. P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88(5), 879–903. <https://doi.org/10.1037/0021-9010.88.5.879>
- (46). Podsakoff, P. M., MacKenzie, S. B., & Podsakoff, N. P. (2012). Sources of method bias in social science research and recommendations on how to control it. *Annual Review of Psychology*, 63, 539–569. <https://doi.org/10.1146/annurev-psych-120710-100452>
- (47). Popović, A., Hackney, R., Coelho, P. S., & Jaklič, J. (2012). Towards business intelligence systems success: Effects of maturity and culture on analytical decision making. *Decision Support Systems*, 54(1), 729–739. <https://doi.org/10.1016/j.dss.2012.08.017>
- (48). Raisch, S., & Krakowski, S. (2021). Artificial intelligence and management: The automation-augmentation paradox. *Academy of Management Review*, 46(1), 192–210. <https://doi.org/10.5465/amr.2018.0072>
- (49). Ringle, C. M., Wende, S., & Becker, J.-M. (2024). *SmartPLS 4* [Logiciel informatique]. SmartPLS GmbH. <https://www.smartpls.com>
- (50). Rönkkö, M., & Evermann, J. (2013). A critical examination of common beliefs about partial least squares path modeling. *Organizational Research Methods*, 16(3), 425–448. <https://doi.org/10.1177/1094428112474693>
- (51). Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005-2019. *Applied Soft Computing*, 90, Article 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- (52). Sharma, P. N., Liengard, B. D., Hair, J. F., Sarstedt, M., & Ringle, C. M. (2023). Predictive model assessment and selection in composite-based modeling using PLS-SEM: Extensions and guidelines for using CVPAT. *European Journal of Marketing*, 57(6), 1662–1677. <https://doi.org/10.1108/EJM-08-2020-0636>
- (53). Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: Guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322–2347. <https://doi.org/10.1108/EJM-02-2019-0189>
- (54). Shrestha, Y. R., Ben-Menahem, S. M., & von Krogh, G. (2019). Organizational decision-making structures in the age of artificial intelligence. *California Management Review*, 61(4), 66–83. <https://doi.org/10.1177/0008125619862257>
- (55). Visinescu, L. L., Jones, M. C., & Sidorova, A. (2017). Improving decision quality: The role of business intelligence. *Journal of Computer Information Systems*, 57(1), 58–66. <https://doi.org/10.1080/08874417.2016.1181494>
- (56). Wamba, S. F., Gunasekaran, A., Akter, S., Ren, S. J.-F., Dubey, R., & Childe, S. J. (2017). Big data analytics and firm performance: Effects of dynamic capabilities. *Journal of Business Research*, 70, 356–365. <https://doi.org/10.1016/j.jbusres.2016.08.009>
- (57). Wang, R. Y., & Strong, D. M. (1996). Beyond accuracy: What data quality means to data consumers. *Journal of Management Information Systems*, 12(4), 5–33. <https://doi.org/10.1080/07421222.1996.11518099>

- (58). Wixom, B. H., & Todd, P. A. (2005). A theoretical integration of user satisfaction and technology acceptance. *Information Systems Research*, 16(1), 85–102.
<https://doi.org/10.1287/isre.1050.0042>
- (59). Zhao, X., Lynch, J. G., & Chen, Q. (2010). Reconsidering Baron and Kenny: Myths and truths about mediation analysis. *Journal of Consumer Research*, 37(2), 197–206.
<https://doi.org/10.1086/651257>

Déclaration relative à l'utilisation de l'intelligence artificielle :

Conformément à la politique éditoriale de la revue, les auteurs déclarent avoir utilisé un outil d'intelligence artificielle générative exclusivement pour la correction linguistique du manuscrit (orthographe, grammaire et syntaxe). Cet outil n'a été utilisé ni pour la conception de l'étude, ni pour la collecte, l'analyse ou l'interprétation des données, ni pour la production du contenu scientifique. Les auteurs ont relu et validé l'ensemble du texte et en assument l'entière responsabilité.