



معهد تمويل التنمية للمغرب العربي  
INSTITUT DE FINANCEMENT  
DU DÉVELOPPEMENT DU MAGHREB ARABE  
www.ifid.org.tn

# LES CAHIERS DE L'IFID

N°8 : Août 2025

1. Gestion des réserves de change : Perspectives et limites de l'intelligence artificielle dans la prévision des rendements obligataires
2. Pricing Of An Index-based Flood Insurance Product Using Satellite Data: Case Of Cereal Production Of The Wilaya of El Tarf -Algeria
3. L'impact de l'obligation du provisionnement des sinistres tardifs de l'Assurance Automobile sur les Compagnies d'Assurances Algériennes « Cas de la SAA »
4. L'impact du risque de liquidité sur la performance bancaire: Cas des Banques Tunisiennes
5. L'impact du système de contrôle de gestion sur la performance globale de la banque (Cas de l'ATB)

**RESPONSABLE DES CAHIERS DE L'I.F.I.D**  
**Amel BOUGHDIRI**

**COORDINATION**  
**Khaled Zouari**

## **Comité de Lecture**

(Par ordre alphabétique des noms)

### **PROFESSEURS UNIVERSITAIRES**

---

**Olfa Ben Ouda**

**Néji Bouslama**

**Mohamed Daouas**

**Riadh El Ferktaji**

**Dorra Hmaied**

**Farouk Kriaa**

**Kamel Naoui**

**Mongi Safra**

**Amel Zenaidi**

### **PROFESSIONNELS DE LA BANQUE**

---

**Chokri Ghanmi**

**Radhouane Gouja**

**Mohamed Kaaniche**

**Wafa Slimène**

**Makrem SASSI**

### **PROFESSIONNELS DE L'ASSURANCE**

---

**Mohamed Najed Ksouri**

**Ghazi Oueslati**

**Mohamed Zouari**

***L'IFID n'entend donner aucune approbation ni improbation aux opinions émises dans les différents articles. Ces opinions doivent être considérées comme propres à leurs auteurs.***

# SOMMAIRE

---

---

Présentation de la Revue de l'IFID par Monsieur *Samir Tembrabet*

---

**1. Gestion des réserves de change : Perspectives et limites de l'intelligence artificielle dans la prévision des rendements obligataires..... 7**

---

**2 Pricing Of An Index-based Flood Insurance Product Using Satellite Data: Case Of Cereal Production Of The Wilaya of El Tarf -Algeria .....36**

---

**3. L'impact de l'obligation du provisionnement des sinistres tardifs de l'assurance Automobile sur les compagnies d'assurances Algériennes « Cas de la SAA ».....54**

---

**4. L'impact du risque de liquidité sur la performance bancaire: Cas des banques tunisiennes..... 77**

---

**5. L'impact du système de contrôle de gestion sur la performance globale de la banque (Cas de l'ATB).....95**

---

## Présentation des articles de la revue :

### Les Cahiers de l'IFID n°8

Par Monsieur Samir TAMRABET  
Diplômé de l'IFID 9eme Promotion Banque  
Directeur Général de la BNA-Algérie

Fidèle à sa mission d'excellence et à sa vocation de former les leaders, l'Institut de Financement du Développement du Maghreb Arab (I.F.I. D) s'affirme comme un pôle de savoir, d'innovation et de rayonnement académique et professionnel. Dans un environnement en constante évolution, marqué par la globalisation, la transition numérique et la complexité croissante des métiers. L'Institut se positionne comme un acteur majeur dans la transmission des compétences, le développement de l'esprit critique et la promotion de la recherche appliquée.

La présente revue incarne cette ambition. Elle se veut un espace privilégié où se croisent réflexions scientifiques, analyses prospectives et témoignages d'expériences professionnelles. Elle a pour objectif de contribuer à l'enrichissement des connaissances, à la valorisation de la recherche et au rapprochement entre le monde académique et les milieux socio-économiques.

Par la qualité et la diversité des contributions au nombre de cinq au titre du présent numéro (08), la publication vise à renforcer le rôle de l'Institut en tant que référence nationale et internationale dans le domaine de la formation supérieure et de la recherche scientifique.

1. Le premier article (de Nour Chemmam- Banque Centrale de Tunisie) présente une analyse de l'efficacité de l'intelligence artificielle, notamment le Deep Learning via le modèle LSTM, dans la prévision des rendements obligataires, un enjeu central pour la gestion des réserves de change.

Historiquement, la prévision s'appuie sur des modèles économétriques comme ceux de la famille GARCH, conçus pour modéliser la volatilité et anticiper les dynamiques des marchés financiers. Cependant, la complexité croissante des interactions de marché a ouvert la voie à l'exploration de solutions IA capables de mieux capturer les relations non linéaires et complexes des séries temporelles.

L'étude compare sept variantes de GARCH à un modèle LSTM, en utilisant trois indicateurs de précision (RMSE, MAE, MAPE). Les résultats montrent que, contrairement aux attentes, les modèles économétriques surpassent le LSTM en précision de prévision, le DCC-GARCH offrant les performances les plus élevées.

Ainsi, l'IA, bien que prometteuse, ne remplace pas encore les approches économétriques traditionnelles dans ce domaine spécifique.

2. Le second article (de Loubna Chikhi -Ministère des Finances-Algérie) présente une étude qui traite du développement d'un produit d'assurance indicielle contre les inondations, adapté au secteur céréalier de la wilaya d'El Tarf, l'une des zones agricoles vulnérables d'Algérie.

Les inondations, fréquentes et coûteuses, exposent fortement la production agricole, alors que les assurances traditionnelles restent limitées par leurs coûts, leur complexité et leurs délais d'indemnisation.

La recherche propose un mécanisme basé sur un indice de précipitations, où l'indemnisation est déclenchée automatiquement lorsque les pluies dépassent un seuil prédéfini. En l'absence de données historiques sur les sinistres, un modèle probabiliste utilisant des données satellitaires et un Modèle Linéaire Généralisé (GLM) a été élaboré. Une fonction de dommage relie les précipitations aux pertes estimées, et la théorie des valeurs extrêmes permet de modéliser les événements rares pour déterminer des tarifs justes et précis.

Ce dispositif vise à offrir aux agriculteurs une protection plus rapide, accessible et adaptée aux risques climatiques croissants.

3. Le troisième article (de Sara Heddi -Ministère des Finances-Algérie), présente une étude d'impact de l'obligation de constituer des provisions pour sinistres tardifs (IBNR) dans l'assurance automobile, en se basant sur le cas de la SAA. Dans le contexte de l'inversion du cycle de production, les assureurs doivent comptabiliser à la fois les sinistres déjà connus et ceux encore non déclarés. Or, en Algérie, l'absence d'obligation formelle de provisionnement IBNR entraîne une sous-estimation des engagements financiers futurs.

L'analyse porte sur les données de 2013 à 2022 et utilise les méthodes actuarielles Chain Ladder, Mack et Bootstrap, estimant les provisions nécessaires à 3 350 millions DA. Les résultats montrent que l'intégration de l'IBNR augmenterait les passifs et réduirait légèrement le résultat net et la marge d'assurance nette (-20 millions DA, soit -0,7% en 2022), mais renforcerait la stabilité financière et la protection des assurés.

L'article conclut à la nécessité d'intégrer l'obligation de provision IBNR dans la réforme du cadre légal des assurances en Algérie afin de limiter les risques de sous-estimation et de garantir la solidité du secteur.

4. Le quatrième article (d'Arwa Masmoudi -Arab Tunisian Bank) analyse l'impact du risque de liquidité sur la performance bancaire en Tunisie, mesurée par la marge nette d'intérêt, à partir de données de dix (10) banques sur la période 2003-2022.

Les résultats montrent qu'un ratio crédits/dépôts plus élevé, un taux de capitaux propres important et une concentration accrue du marché améliorent significativement la performance. En revanche, la proportion de prêts non-performants et la taille de la banque affectent négativement la marge nette d'intérêt.

Ces conclusions soulignent l'importance pour les banques tunisiennes de maîtriser leur risque de liquidité et d'optimiser leur structure financière afin d'améliorer leurs performances.

5. Le cinquième article (d'Ameni Touffeh -Arab Tunisian Bank) analyse l'impact du système de contrôle de gestion sur la performance globale de la banque, à partir d'une enquête quantitative menée auprès de 100 directeurs et chefs d'agence de l'ATB.

L'analyse par modélisation d'équations structurelles (AMOS) révèle que la composante informelle du contrôle de gestion exerce une influence positive significative sur la performance, mettant en évidence l'importance des interactions non formelles dans le succès de l'institution.

Le partage des connaissances et l'apprentissage organisationnel apparaissent également comme des leviers clés d'amélioration des résultats.

Ces conclusions invitent à adopter, dans le cadre de la gestion bancaire, une approche combinant structures formelles et mécanismes informels pour soutenir une performance durable.

M. TAMRABET Samir  
Diplômé de l'IFID 9eme Promotion Banque  
Actuel Directeur Général de la BNA-Algérie  
Ex. Directeur Général de la CNEP-Banque  
Ex. Présient du Conseil d'Administration de l'IFID

## Gestion des réserves de change : Perspectives et limites de l'intelligence artificielle dans la prévision des rendements obligataires

Nour CHEMMAM

Banque Centrale de Tunisie



### Résumé

La prévision des rendements des obligations d'Etat, cœur du métier de la gestion des réserves, est l'une des tâches les plus ardues sur les marchés financiers (Shu et Chou, 2021).

Les pionniers de la prévision sont les modèles économétriques, notamment la famille GARCH. Bien que ces modèles soient développés pour la modélisation de la volatilité, un outil essentiel pour saisir la dynamique des marchés et prévoir le comportement des actifs financiers, le dynamisme intense du marché financier et la complexité croissante de ses interactions ont accentué les défis spécifiques liés à la modélisation. Au-delà des modèles classiques, les modèles de DL, notamment le LSTM, se sont établis comme des outils puissants pour la prévision des séries temporelles financières. De nombreuses recherches soulignent leur potentiel en tant qu'alternative aux modèles économétriques. L'objectif de ce travail de recherche est d'évaluer si les approches modernes d'IA, avec leur flexibilité et leur capacité à capturer les dynamiques complexes présentes dans les séries temporelles, peuvent surpasser les méthodes classiques en termes de précision de prévision. En recourant à trois mesures de la précision des prévisions (RMSE, MAE et MAPE), nous comparons la qualité prévisionnelle de sept variantes du GARCH avec celle du LSTM. Nos résultats révèlent la supériorité des modèles économétriques sur le modèle LSTM. Par ailleurs, parmi les modèles économétriques, le modèle DCC-GARCH s'est distingué en offrant les prévisions les plus précises.

**Mots Clés** : Prévision des rendements obligataires, Intelligence artificielle (IA), Deep-Learning (DL), Long Short Term Memory (LSTM), gestion des réserves de change, allocation stratégique en actifs (ASA).

### Introduction

Les modèles de prévision des variables financières n'ont cessé d'évoluer, s'adaptant aux exigences croissantes imposées par la complexité et la dynamique des marchés financiers. Les modèles économétriques, et en particulier les modèles GARCH, constituent les pionniers dans le domaine de la prévision des séries temporelles financières. Leur grande notoriété repose sur leur aptitude à capturer la volatilité conditionnelle, caractéristique des marchés financiers, ainsi que les corrélations conditionnelles, notamment grâce à des extensions avancées telles que le modèle DCC-GARCH. Cependant, l'évolution constante des marchés financiers a soulevé des interrogations concernant la capacité des modèles économétriques à capturer pleinement les différents patterns des actifs financiers et à saisir adéquatement la complexité et la non-linéarité qui caractérisent les interactions entre les variables. Cela a conduit à l'émergence de nouvelles approches, complémentaires et alternatives, en matière de prévision. Particulièrement, les avancées récentes des techniques d'apprentissage automatique ont marqué une véritable révolution dans la prévision des marchés financiers, offrant de nouvelles perspectives et améliorant la précision prédictive (Li, Wang et Chen, 2024). De nombreuses études, à l'instar de celles de Mo et al. (2024) ; Liu et al. (2024) ; Jin et al. (2024) ; Bagastio et al. (2023) et Rahimi (2020), soulignent le potentiel élevé des algorithmes d'apprentissage automatique, les positionnant comme une alternative prometteuse aux modèles de prévision classiques, notamment les modèles économétriques.

Conscients de l'importance cruciale de la prévision des rendements obligataires, et s'inscrivant dans les efforts continus des banques centrales (BC) pour identifier et développer des approches



novatrices visant à optimiser l'ASA, ce travail de recherche s'est attelé à évaluer l'apport de l'intelligence artificielle (IA), particulièrement le Deep- Learning (DL), en termes de performance prédictive, en comparaison avec les modèles économétriques classiques, en particulier les modèles GARCH.

À notre connaissance, ce travail de recherche représente une modeste contribution, quoi que novatrice, en explorant l'apport d'un modèle de DL par rapport aux modèles économétriques classiques en termes de performance prévisionnelle, spécifiquement pour les rendements des obligations gouvernementales de la zone euro, en prenant en compte huit déterminants financiers et macroéconomiques. De plus, ce travail marque la première proposition d'application d'un modèle de DL à la gestion des réserves.

## 1. Revue de la littérature

### 1.1. L'allocation stratégique en actifs (ASA)

L'ASA est un instrument indispensable à une gestion optimale des réserves de change. La décision d'ASA définit le portefeuille de long terme optimal, celui qui maximise le rendement total attendu tout en respectant les objectifs de gestion des réserves, l'horizon d'investissement et la tolérance au risque de la BC. L'ASA est généralement élaborée par l'optimisation du portefeuille des réserves de change. Un cadre typique pour sa conception est composé des étapes suivantes (Berkelaar, Coche et Nyholm, 2010) :

- L'articulation des objectifs de gestion des réserves ;
- La spécification des mesures de risque utilisées pour définir la tolérance de la BC aux risques ;
- La définition l'horizon d'investissement ;
- La définition de l'univers d'investissement ;
- L'établissement des prévisions des rendements futurs des actifs de l'univers d'investissement ;  
et
- La formalisation du processus d'optimisation pour la dérivation d'une proposition de l'ASA.

Parmi ces différentes étapes, la prévision des rendements futurs des actifs d'investissement, en particulier les obligations revêt une importance stratégique. En effet, la fiabilité et la pertinence de l'ASA sont conditionnées par la précision des prévisions sur lesquelles elle repose.

### 1.2. Les approches de prévision des rendements obligataires

Les approches de prévision des rendements obligataires abordées dans la littérature se répartissent en deux grandes catégories, à savoir : les méthodes classiques, et les modèles d'IA.

#### 1.2.1. Les modèles classiques de prévision des rendements obligataires

Ces modèles englobent les méthodes de modélisation de la courbe entière, initiés par Nelson et Siegel en 1987 avec le modèle à trois facteurs (Nelson-Siegel, NS), ainsi que les modèles économétriques, notamment le modèle ARCH (General AutoRegressive Conditional Heteroscedastic) (Engle, 1982) avec sa forme généralisée GARCH (AutoRegressive Conditional Heteroscedastic).

En effet, la modélisation de la volatilité est un outil essentiel pour comprendre la dynamique des marchés ainsi que pour la prévision des comportements des actifs financiers. Trois faits stylisés caractérisent les séries temporelles financières (McNeil et al., 2005) : Les séries des rendements sont leptokurtiques ;

- Leur volatilité est conditionnelle ; et

- Elles présentent un phénomène de regroupement de volatilité (volatility clustering)<sup>1</sup>.

Pour répondre à cet objectif, trois modèles économétriques se distinguent, soit GARCH, EGARCH et DCC-GARCH. Le modèle GARCH, introduit par Engle en 1982, a été conçu spécifiquement pour capturer la dynamique temporelle de la volatilité. Le modèle EGARCH (Exponential Generalized Autoregressive Conditional Heteroskedasticity) est une extension du modèle GARCH, développée par Tim Bollerslev en 1991 pour capturer les effets asymétriques des chocs positifs et négatifs, de même ampleur, sur la volatilité. Le modèle le DCC-GARCH (Dynamic Conditional Correlation GARCH), développé par Engle (2002) et Tse et Tsui (2002) est une extension du modèle GARCH qui permet de modéliser les volatilités conditionnelles de plusieurs séries temporelles simultanément ainsi que leurs corrélations conditionnelles.

### 1.2.2. Les modèles avancés de prévision des rendements obligataires : les modèles d'IA

Au-delà des modèles classiques, les récents progrès des techniques d'apprentissage automatique ont révolutionné les marchés financiers, offrant de nouvelles perspectives et améliorant la précision prédictive. Parmi ces technologies prédictives, le DL<sup>2</sup> a reçu une attention considérable grâce à sa capacité à extraire et représenter des abstractions de haut niveau à partir des jeux de données (Rahimi, 2020). Dans le domaine de DL, Les Réseaux de Neurones Récurrents (RNN) et le réseau de mémoire à court et long terme (Long Short Term Memory, LSTM) se distinguent.

En effet, Une caractéristique importante des modèles RNN est leur capacité à prendre en entrée et à produire en sortie des séquences de différentes longueurs. Avec cette nature séquentielle, il y'a une modélisation explicite de la structure temporelle des séries. Par ailleurs, les RNN se distinguent par l'utilisation, dans le traitement des séquences, de boucles de rétroaction qui permettent aux informations de persister, effet assimilé à la mémoire.

Cependant, les RNN, souffrent d'un problème majeur, soit la « disparition du gradient », ce qui les rend incapables de capter et d'apprendre les dépendances de long terme.

Pour pallier cette limite et tenir compte de ces dépendances, caractéristique fondamentale des séries temporelles notamment financières, les réseaux à Mémoire à long terme et à court terme (LSTM) ont été développés en 1997 par Hochreiter et Schmidhuber. Les LSTM sont un type spécial de RNN, conçu spécifiquement pour capturer et apprendre les dépendances à long terme. En effet, dans le cas des RNN, les cellules ont une seule fonction. En revanche, l'architecture d'une cellule LSTM est considérablement plus complexe, basée sur un mécanisme de portes (input gate, forget gate et output gate) qui régulent le flux d'informations à travers le réseau et sur un état de mémoire (cell state)  $c_t$ , qui représente la mémoire à long terme (Li, Wang et Chen, 2024).

Ainsi, dans les LSTM, les gradients sont stabilisés grâce à  $c_t$ , qui assure une propagation plus stable.

Une unité LSTM dispose de quatre fonctions :

$$\begin{aligned}
 f_t &= \sigma(W_{hf}h_{t-1} + W_{xf}x_t) \\
 i_t &= \sigma(W_{hi}h_{t-1} + W_{xi}x_t) \\
 o_t &= \sigma(W_{ho}h_{t-1} + W_{xo}x_t) \\
 c_t &= f_t * c_{t-1} + i_t * \tanh(W_{hh}h_{t-1} + W_{xh}x_t) \\
 h_t &= o_t * \tanh(c_t)
 \end{aligned}$$

<sup>1</sup> « Une journée à forte volatilité est généralement suivie d'un autre jour à forte volatilité tandis qu'un jour à faible volatilité est souvent suivi d'un autre jour à faible volatilité » (FARAHVASH,2020).

<sup>2</sup> Le DL est une branche du Machine Learning qui s'appuie sur les réseaux neuronaux artificiels (RNA) comme cadre pour apprendre à partir des données.

Dans les marchés de capitaux, les RNN et les LSTM se sont révélés efficaces pour prédire les cours boursiers : Jin et al., 2024 ; Liu et al., 2024 ; Mo et al., 2024 ; et Zhu et al., 2024 ; Wang et al. (2024), Bagastio et al. (2023), Ding et Qin (2019), Lopez de Prado (2018) ainsi que Tsai et al. (2017). Ces résultats prometteurs signifient que le DL peut être un outil puissant pour la prévision des prix des actifs (Rodrigues, 2020). Cependant, bien que les RNN et les LSTM aient été largement utilisés pour la prédiction des cours boursiers, le marché obligataire demeure moins exploité.

### 1.2.3. Les modèles d'IA vs les modèles économétriques classiques

Les séries financières temporelles ont tendance à suivre certains patterns<sup>3</sup>. Un modèle doté d'une mémoire et capable de capturer et d'apprendre les dépendances à long terme est ainsi requis pour la prévision de ces séries.

Bien que les modèles de la famille GARCH aient démontré une grande efficacité pour capturer les comportements de la volatilité, ils peuvent néanmoins présenter des difficultés à saisir la complexité des dynamiques changeantes et non linéaires des interactions entre les variables.

Dans cette optique, les techniques de DL offrent des perspectives prometteuses pour la modélisation et la prévision des données financières, notamment grâce à leur capacité à capturer les relations complexes et non linéaires au sein des données, qui peuvent échapper aux approches traditionnelles.

Contrairement aux modèles économétriques, le LSTM ne fait pas d'hypothèses préalables quant à la fonction de mapping et sont, ainsi, capables d'identifier et d'exploiter les patterns complexes.

Également, par opposition aux modèles économétriques classiques, le LSTM n'est pas soumis à des contraintes statistiques, telles que la stationnarité, l'absence de multi colinéarité... souvent requises pour garantir la validité des résultats dans les approches économétriques classiques.

Toutes ces caractéristiques rendent ce modèle bien adapté à la volatilité inhérente aux marchés financiers et aux corrélations dynamiques de leurs variables, suggérant ainsi un potentiel de performance prédictive supérieur par rapport aux modèles économétriques.

## 2. Revue des travaux de recherche

En 2006, Castellani et Santos ont comparé la performance des RNA par rapport à celle du modèle ARIMA en termes de prévision du rendement des obligations du Trésor américain à 10 ans. Les auteurs ont considéré quatre indicateurs économiques, à savoir : l'indice d'achat des directeurs (PMI), l'IPC, le Libor et l'indice de volatilité (VIX). Selon les auteurs, les meilleurs résultats ont été obtenus par le modèle ARIMA.

Avec des résultats différents, Dunis et Morrison (2007) ont également comparé la performance des RNA et du modèle ARMA pour la prévision du rendement des obligations d'État à 10 ans du Royaume-Uni, des États-Unis et de la zone euro, en intégrant 3 variables financières, à savoir : les indices des prix des actions, les taux de change et les prix des MP. Les résultats de cette étude ont montré que les réseaux de neurones offrent les meilleures précisions. Les auteurs ont conclu que les modèles de DL représentent une alternative prometteuse aux techniques classiques.

En 2023, Poncea, Diazb et Astudillo ont cherché à comparer la précision prédictive du modèle LSTM, avec celle du modèle conventionnel ARIMA en utilisant le RMSE. Les auteurs ont employé un modèle LSTM et un modèle ARIMA pour chaque maturité de la courbe. Leurs résultats indiquent que les modèles LSTM sont plus performants que l'ARIMA.

Li, Wang, et Chen (2024) ont exploré l'application des RNN et du LSTM pour la prévision des rendements des obligations du Trésor américain. Leur analyse a intégré quatre indicateurs économiques clés à savoir l'Indice des Prix à la Consommation (CPI), l'Indice des Prix à la Production (PPI), le Produit Intérieur Brut (PIB) et les Ventes au Détail. Les auteurs ont conclu que le LSTM s'est avéré supérieur

---

<sup>3</sup> L'architecture du modèle en couches et la structure des cellules de mémoire permet au modèle de détecter les dépendances temporelles et les corrélations dans les données, ce qui conduit à l'apprentissage de schémas (patterns) qui s'étendent sur plusieurs pas de temps.

pour capturer les dépendances temporelles et tenir compte des relations complexes et non linéaires inhérentes aux données économiques.

### 3. Etude empirique

Cette étude empirique vise à évaluer dans quelle mesure l'adoption de l'IA pourrait améliorer l'optimisation de l'ASA des BC. En recourant à trois mesures de la précision des prévisions (RMSE, MAE et MAPE), nous comparons la qualité prévisionnelle de sept variantes<sup>4</sup> du modèle GARCH (GARCH, EGARCH, GARCH-X, EGARCH-X, ARMAX-GARCH, ARMAX-EGARCH et DCC-GARCH) avec celle du modèle de DL le plus couramment utilisé dans la prévision des séries temporelles financières, le modèle « LSTM ».

Par ailleurs, dans le but d'améliorer la qualité prévisionnelle de nos modèles, nous suivons les recommandations de Monch (2008) ainsi que Rudebusch et Aruoba (2006), qui soulignent l'importance d'intégrer des variables financières et macroéconomiques dans les modèles de prévision. Ces auteurs affirment que cette approche permet d'optimiser la performance prédictive des modèles et d'accroître la fiabilité des résultats obtenus. Ils expliquent que la macroéconomie impacte la trajectoire future de la courbe de rendement, et attribuent cette influence aux interactions dynamiques entre les différentes variables au sein du marché financier. Ces recommandations ont également été reprises par Shu et Chou (2021), qui insistent sur la complexité des interactions entre les déterminants et les rendements obligataires, soulignant la nécessité d'une analyse approfondie et rigoureuse de ces relations pour garantir des prévisions fiables et pertinentes.

#### 3.1. Présentation des données

D'après notre analyse des différents travaux de recherche portant sur les instruments à revenu fixe, il n'a pas été possible de trouver une solution directe pour modéliser/ prévoir la courbe des taux de rendement à l'aide des modèles économétriques ni des modèles de ML. Il s'agit d'une lacune en termes de recherche académique. Ces constats ont été confirmés par Li, Wang and Chen (2024). Ainsi, la prévision de la courbe de taux de rendement sera effectuée à travers la prévision de ses benchmarks les plus pertinents. Selon les praticiens et les théoriciens, les benchmarks les plus considérés pour les obligations souveraines sont les rendements obligataires à 3 mois, 12 mois, 2, 5, 7, 10 et 30 ans. Cependant, pour des raisons techniques, et en tenant compte de la contrainte de durée maximale<sup>5</sup> typique du portefeuille des réserves des BC, nous avons sélectionné les maturités<sup>6</sup> : 3 mois, 12 mois, 2, 5, et 10 ans, représentant cinq cibles à prévoir.

Pour enrichir nos modèles, nous avons intégré huit variables exogènes en tant que déterminants des rendements obligataires. Pour tous les modèles, la méthodologie adoptée consiste à prévoir le rendement de chaque maturité, en s'appuyant sur des variables exogènes (features) qui représentent les principaux déterminants de ce rendement.

Les variables retenues pour cette étude sont les suivantes :

- Variables endogènes : Les rendements des obligations de la zone euro, à maturités : 3 mois, 1 an, 2 ans, 5 ans et 10 ans. Ce choix s'aligne avec les objectifs de préservation du capital (catégorie : Investment grade), et de liquidité (L'euro est la deuxième devise la plus liquide sur le marché des changes<sup>7</sup>) des banques centrales, ainsi que la contrainte de durée maximale typique du portefeuille des réserves des BC. Source : site de la BCE.

<sup>4</sup> Ce choix méthodologique s'appuie sur une analyse approfondie des travaux de recherche existants ayant exploré des problématiques similaires.

<sup>5</sup> Pour gérer le risque de taux d'intérêt, les BC fixent souvent des limites de durée maximale pour le portefeuille total des réserves ainsi et pour les sous-portefeuilles (tranches). Fin 2022, la durée moyenne de la tranche fonds de roulement était inférieure à 8 mois, celle de la tranche de liquidité était de 10 mois, tandis que celle de la tranche d'investissement atteignait 29 mois (L'enquête du RAMP de 2023).

<sup>6</sup> Ces obligations sont des titres à échéance fixe pour lesquels la BCE calcule un rendement quotidien.

<sup>7</sup> Les données de l'Enquête triennale de la BRI auprès des BC sur les opérations de changes de 2019 montrent que l'EUR est présent dans 32,3 % des transactions de change dans le monde.

- Variables exogènes :

Variable exogène	Description
<b>Variables financières</b>	
EESWE2 BGN Curncy, EESWE5 BGN Curncy et EESWE10 BGN Curncy	Des taux de swap indexés sur les taux du jour au lendemain (overnight) journaliers ; les swaps ayant pour maturités : 2 ans, 5 ans et 10 ans respectivement. Source : Bloomberg.
VSTOXX (L'indice de volatilité Euro Stoxx 50)	Un indice qui mesure la volatilité future à court terme de l'indice Euro STOXX 50, soit la volatilité implicite dans les options sur l'Euro STOXX 50, ayant une date d'expiration à court terme. C'est indice reflète les anticipations des investisseurs quant à la volatilité du marché à court terme. Plus précisément, le VSTOXX traduit le degré d'incertitude et de risque perçus dans le marché européen. Source : le site STOXX.
MSFXEURINDEX (Morgan Stanley Foreign Exchange Euro Index) <sup>8</sup>	Un indice financier spécialement conçu pour évaluer et suivre l'évolution de la valeur de l'euro par rapport à un panier de devises étrangères. Cet indice permet d'analyser la performance de l'euro sur le marché de changes. Source : Bloomberg.
<b>Prix des matières premières</b>	
Gold	La cotation journalière d'une once d'or (environ 31,1 grammes). Source : Bloomberg.
<b>Variables macroéconomiques</b>	
M2	La masse monétaire au sens de M2. Source : Eurostat
Inflation	Le taux d'inflation : L'inflation est mesurée par le taux de croissance de l'indice des prix à la consommation harmonisé » (IPCH). Source : Eurostat.
Dettes gouvernementales (GOV)	La dette publique agrégée de la zone euro. Site : BCE.
L'EURIBOR à 3 mois et l'EURIBOR à 12 mois	Les taux d'intérêt moyens auxquels un groupe de grandes banques européennes se consentent des prêts en euros sur une échéance de 3 mois et de 12 mois, respectivement. Source : Bloomberg.

Pour la variable inflation (à fréquence mensuelle) et la variable dette gouvernementale (à fréquence trimestrielle), nous avons effectué une désagrégation temporelle à l'aide du package « tempdisagg » dans le logiciel R, afin d'adapter ces données à la fréquence journalière de la variable cible. Les codes relatifs à cette désagrégation sont fournis en annexes n°1 et 2.

Pour chaque rendement obligataire, un ensemble spécifique de variables explicatives est sélectionné. Ce choix repose sur une analyse approfondie de la littérature existante sur les déterminants des rendements, tout en tenant compte de la maturité de l'obligation concernée (les maturités longues et courtes réagissant souvent de manière différente aux mouvements des marchés financiers (Rodrigues, 2020)). Les déterminants de chaque rendement sont présentés dans le tableau suivant :

<sup>8</sup> Il est à noter que nous avons cherché à utiliser les taux FX FUTURE avec des maturités équivalentes aux maturités des obligations étudiées, ce qui aurait été plus pertinent pour notre analyse, mais nous étions contraints par la disponibilité des historiques de données. En effet, l'historique des indices ECZ4 COMB Curncy, ECZ5 COMB Curncy, ECZ6 COMB Curncy... relatifs à la parité EUR/USD ne remontent qu'à l'année 2019.

Variable cible (Target)	Rendement de 3 mois	Rendement de 12 mois	Rendement de 2 ans	Rendement de 5 ans	Rendement de 10 ans
Les variables exogènes (Features)	<ul style="list-style-type: none"> <li>• Euribor 3 mois</li> <li>• L'inflation</li> <li>• VSTOXX</li> <li>• M2</li> <li>• MSFXEUR index</li> </ul>	<ul style="list-style-type: none"> <li>• Euribor 12 mois</li> <li>• L'inflation</li> <li>• VSTOXX</li> <li>• M2</li> <li>• MSFXEUR index</li> </ul>	<ul style="list-style-type: none"> <li>• EESWE2 BGN Curncy</li> <li>• L'inflation</li> <li>• Dette gouvernementale</li> <li>• M2</li> <li>• MSFXEUR index</li> </ul>	<ul style="list-style-type: none"> <li>• EESWE5 BGN Curncy</li> <li>• Prix de l'or</li> <li>• Dette gouvernementale</li> <li>• M2</li> <li>• MSFXEUR index</li> </ul>	<ul style="list-style-type: none"> <li>• EESWE10 BGN Curncy</li> <li>• Prix de l'or</li> <li>• Dette gouvernementale</li> <li>• M2</li> <li>• MSFXEUR index</li> </ul>

Dans cette analyse, la période comprise entre le 15 octobre 2010 et le 30 septembre 2024 a été considérée, ce qui donne un total de 3642 observations historiques journalières.

Cette fenêtre couvre les périodes qui ont le plus marqué l'économie de la zone euro, notamment la crise de la dette souveraine européenne et, plus récemment, la pandémie du Covid-19 et offre une base de données suffisamment étendue pour rendre compte de la pertinence des résultats, notamment ceux du modèle d'IA, exigeant un tas important de données. La méthode d'interpolation linéaire a été utilisée pour traiter les valeurs manquantes.

L'horizon de prévision couvre 364 jours, soient 364 prévisions de rendement journalier pour chacune des cinq maturités considérées. La durée de cet horizon assure une évaluation précise de la qualité prédictive des modèles.

### 3.2. Analyse statistique descriptive des variables

L'analyse graphique révèle que les séries des rendements des obligations affichent une légère tendance baissière durant la période 2010-2021, suivie d'une augmentation brusque à partir de 2022. Un constat similaire s'applique aux taux de swap, à l'Euribor et à l'inflation. Ces évolutions suggèrent la présence de ruptures structurelles dans ces séries temporelles, potentiellement induites par les effets combinés de la pandémie de COVID-19 et de la guerre russo-ukrainienne. Ces considérations justifient le recours aux approches suivantes : Le test « Zivot-Andrews » pour l'examen de la stationnarité, le modèle DCC-GARCH pour la capturer les corrélations conditionnelles entre les variables, et le modèle LSTM pour capturer les dépendances non linéaires entre les variables.

Analyse de la normalité : Pour toutes les séries analysées, les statistiques de JB sont toutes supérieures à la valeur critique, avec des probabilités inférieures à 5% (égales à 0.00%). Par conséquent, l'hypothèse nulle de la normalité est rejetée. Par ailleurs, les coefficients de Kurtosis sont tous supérieurs à 3, à l'exception de la variable EESWE10BGN\_CURNCY. Il en ressort que les distributions analysées présentent un caractère leptokurtique.

Analyse de la volatilité : Analyse de la dépendance des résidus et test effet ARCH : Les résultats indiquent que l'hypothèse nulle d'absence d'autocorrélation des résidus peut être rejetée au seuil de significativité de 1% (la p-value étant inférieure à 1%). De même, l'hypothèse nulle d'absence d'effets ARCH au sein des séries de rendements des obligations, ventilées par maturités, peut également être rejetée, la p-value étant nulle (inférieure à 1%). Ces résultats suggèrent la présence d'hétéroscédasticité conditionnelle et la possibilité d'un phénomène de regroupement de volatilité. Par conséquent, la modélisation de type GARCH est adéquate.

Etude de la stationnarité : Test de racine unitaire : Les résultats du test ZA montrent que les différentes séries sont stationnaires en niveau, à l'exception des variables YIELD10YEARS, EESWE10BGN\_CURNCY, VSTOXX et le taux d'inflation qui sont intégrées d'ordre 1 (I(1)). Par

conséquent nous devons prendre les séries en différence première ou en différence logarithmique (GROWTH) dans nos modèles.

Test de multi-colinéarité : Les valeurs du VIF sont toutes très proches ou inférieures à 1,5, ce qui indique une faible multi-colinéarité entre les variables explicatives. Ces résultats renforcent la fiabilité des résultats économétriques et permettent des interprétations robustes des coefficients.

**3.3.Présentation des modèles économétriques**

Modèle	Formulation
GARCH	$r_t = \mu_t + \varepsilon_t$ $\varepsilon_t = \sqrt{h_t} * z_t$ $h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + \beta_1 h_{t-1} + \dots + \beta_p h_{t-p}$ $h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}$ <p>Avec : <math>r_t</math> : le rendement de l'actif, à la date <math>t</math>  <math>\mu_t</math> : la moyenne du rendement  <math>\varepsilon_t</math> : Innovation ou résidu ou choc  <math>h_t</math> : la variance conditionnelle à la date <math>t</math>  <math>z_t</math>: Séquence de variables aléatoires i. i. d <math>\sim N(0,1)</math>  <math>\alpha_0, \alpha_q, \beta_p</math> : paramètres du modèle</p>
EGARCH	$r_t = \mu_t + \varepsilon_t$ $\varepsilon_t = \sqrt{h_t} * z_t$ $\log(h_t) = \alpha_0 + \sum_{i=1}^q \alpha_i \left  \frac{\varepsilon_{t-i}}{\sqrt{h_{t-i}}} \right  + \sum_{i=1}^q \gamma_i \frac{\varepsilon_{t-i}}{\sqrt{h_{t-i}}} + \sum_{j=1}^p \beta_j \log(h_{t-j})$ <p>Avec <math>\alpha_i</math> : Paramètres de la partie ARCH  <math>\beta_j</math> : Paramètre de la partie GARCH  <math>\gamma_i</math> : Paramètre de levier / l'effet d'asymétrie</p>
GARCH-X	$r_t = \mu_t + \sum_{k=1}^m \theta_k z_{k,t} + \varepsilon_t$ $h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}$ <p>Avec :  <math>z_{k,t}</math> : k-ème variable exogène  <math>\theta_k</math> : coefficient de la k-ème variable exogène  <math>m</math> : le nombre de variables exogènes</p>

EGARCH-X	$r_t = \mu_t + \sum_{k=1}^m \theta_k z_{k,t} + \varepsilon_t$ $\log(h_t) = \alpha_0 + \sum_{i=1}^q \alpha_i \left  \frac{\varepsilon_{t-i}}{\sqrt{h_{t-i}}} \right  + \sum_{i=1}^q \gamma_i \frac{\varepsilon_{t-i}}{\sqrt{h_{t-i}}} + \sum_{j=1}^p \beta_j \log(h_{t-j})$
ARMAX-GARCH	$x_t = \sum_{i=1}^p \alpha_i x_{t-i} + \varepsilon_t + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \sum_{k=1}^m \theta_k z_{k,t}$
ARMAX-EGARCH	<p>Avec :</p> <p><math>x_t</math> : la valeur de la série temporelle à la date t</p> <p><math>\alpha_i</math> : les coefficients de la partie autorégressive (AR)</p> <p><math>\beta_j</math> : les coefficients de la partie moyenne mobile (MA)</p> <p><math>\varepsilon_t</math> : le terme d'erreur (choc aléatoire ou innovation) à la date t (un bruit blanc)</p> <p><math>p</math> : l'ordre du processus AR</p> <p><math>q</math> : l'ordre du processus MA</p> <p><math>z_{k,t}</math> : k-ème variable exogène</p> <p><math>\theta_k</math> : coefficient de la k-ème variable exogène</p> <p><math>m</math> : le nombre de variables exogènes</p>
DCC-GARCH	$r_t = \mu_t + \varepsilon_t$ $\varepsilon_t = H_t^{1/2} * Z_t$ <p>Avec : <math>r_t</math> : Le vecteur des rendements (<math>n \times 1</math>) à la date t</p> <p><math>n</math> : le nombre d'actifs</p> <p><math>\mu_t</math> : Le vecteur des moyennes des rendements (<math>n \times 1</math>)<sup>9</sup></p> <p><math>\varepsilon_t</math> : le vecteur des résidus (appelées également innovations)<sup>10</sup></p> <p>tel que <math>E(\varepsilon_t) = 0</math> et <math>cov(\varepsilon_t) = H_t</math></p> <p><math>Z_t \text{ iid} \sim N(0, I_n)</math> avec <math>I_n</math> : la matrice identité</p> <p><math>H_t</math> : La matrice variances – covariances conditionnelles (<math>n \times n</math>) à la date t</p> $H_t = D_t R_t D_t$ <p><math>D_t</math> : La matrice des écart – types conditionnels des <math>\varepsilon_t</math> à la date t</p> <p><math>R_t</math> : La matrice des corrélations conditionnelles des <math>\varepsilon_t</math> à la date t.</p>

Dans cette étude, le modèle GARCH (1.1) a été adopté étant donné qu'il est suffisant pour capter le phénomène de volatility clustering dans les données financières (Brooks, 2008). De nombreuses applications empiriques (Gokcan, 2000 ; Franses et Van Dijk, 1996 et Pagan et Schwert, 1990), confirment que GARCH (1,1) capture efficacement le phénomène de variance conditionnelle.

<sup>9</sup>  $\mu_t$  est un vecteur de constantes

<sup>10</sup> C'est la partie aléatoire du rendement (écart par rapport à la moyenne)



### 3.4.Méthodologie d'implémentation du modèle LSTM pour la prévision des rendements obligataires

L'implémentation du modèle de réseau de neurones LSTM pour la prévision des rendements obligataires suit plusieurs étapes bien définies et cruciales pour garantir la performance et la fiabilité du modèle. Cette section décrit en détail chaque étape du processus<sup>11</sup>.

- 1- La normalisation des données : les données d'entrée sont normalisées en utilisant la fonction « MinMaxScaler » de la bibliothèque scikit-learn. Cela permet de mettre toutes les variables à une unique échelle (entre 0 et 1).
- 2- La division des données en échantillons : A l'aide de la fonction « train\_test\_split »<sup>12</sup>, les données sont divisées en 3 échantillons : Un échantillon d'entraînement (Destiné à l'apprentissage du modèle), un échantillon de validation (Permet d'éviter le surapprentissage et de choisir les meilleurs hyperparamètres) et un échantillon de test (Permet de tester la capacité de généralisation du modèle).
- 3- La conception du modèle séquentiel LSTM : La conception du réseau LSTM se fait avec l'aide de la bibliothèque Keras.
  - Structure du réseau : Notre modèle LSTM est composé d'une couche d'entrées, deux couches LSTM, chacune suivie d'une couche de dropout et d'une couche finale d'output. Le nombre d'unités par couche LSTM, le taux de dropout ainsi que le type d'optimisateur sont des hyperparamètres qui seront optimisés.
  - Définition des dimensions d'entrées : Le modèle LSTM reçoit en entrée des données sous une forme tridimensionnelle : Nombre total d'observations (n\_samples), longueur de séquence (n\_steps) et le nombre de variables (n\_features).
  - Compilation du modèle : Le modèle est configuré avec deux types d'optimiseurs : adam et rmsprop, et une fonction de perte : l'erreur quadratique moyenne (MSE).
- 4- Création des séquences pour l'entraînement et la validation du modèle LSTM.
- 5- La construction du modèle LSTM : Soit : La création d'un modèle séquentiel vide, la définition de la forme de l'entrée, l'ajout de la première couche LSTM avec des hyperparamètres optimisés, l'ajout d'une couche de dropout<sup>13</sup> avec un hyperparamètre optimisé : le taux de dropout, l'ajout d'une deuxième couche<sup>14</sup> LSTM avec des hyperparamètres optimisés, l'ajout d'une deuxième couche de dropout avec un hyperparamètre optimisé : taux de dropout, et l'ajout de la couche de sortie.
- 6- La recherche des meilleurs hyperparamètres pour le modèle : Le processus de recherche est mené à l'aide de Keras Tuner et se décompose en de deux étapes :
  - a. La création du tuner pour l'optimisation des hyperparamètres, avec la classe « RandomSearch » de la bibliothèque Keras Tuner, et la configuration du tuner avec les paramètres : la fonction de création du modèle (build\_lstm\_model), la fonction objectif (val\_loss), le nombre maximum d'essais (max\_trial), et le nombre d'exécutions par configuration (executions\_per\_trial).
  - b. La recherche des hyperparamètres : Soit l'entraînement du modèle avec les différentes configurations tout en évaluant chaque modèle sur l'échantillon de validation. Les paramètres de la recherche sont : la plage de la valeur de l'hyperparamètre (max\_value et min\_value), le pas (step), le tuner et le nombre d'époques (epochs).
- 7- La construction du modèle avec les meilleurs hyperparamètres.
- 8- L'entraînement du modèle avec les meilleurs hyperparamètres : Pendant l'entraînement, les poids du modèle sont mis à jour de sorte à minimiser l'erreur de prévision. Ce processus est réalisé de manière itérative, selon les étapes suivantes : Initialisation des poids du modèle de manière aléatoire, la prévision, le calcul de l'erreur, l'optimisation et la validation.

<sup>11</sup> Le code du modèle LSTM est présenté dans l'annexe n°3.

<sup>12</sup> Il est à noter qu'étant donné qu'il s'agit de séries temporelles, où l'ordre des observations est important, la spécification « shuffle=False » a été ajoutée au code.

<sup>13</sup> Le Dropout empêche le réseau de s'ajuster trop aux données d'entraînement, ce qui améliore sa capacité de généralisation.

<sup>14</sup> Ajouter une deuxième couche LSTM permet au modèle d'apprendre des relations temporelles plus complexes.

Le processus d'ajustement des poids du modèle se fait à travers la rétropropagation (le calcul des gradients<sup>15</sup> de la fonction de perte par rapport aux poids du modèle) et la descente de gradient.

Les paramètres de l'entraînement sont : Le nombre d'époques et la taille du lot (batch size).

- 9- La prévision, la mise à l'échelle inverse des prévisions et l'évaluation du modèle. La performance du modèle est évaluée à l'aide de trois mesures, soient : l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) et l'erreur absolue en pourcentage (MAPE).

Les différentes valeurs spécifiées pour les paramètres du modèle LSTM sont présentées dans le tableau suivant :

	Paramètre	Valeur
	n_steps	10
	max_trials	10
	executions_per_trial	1
	epochs	50
	batch size	32
Paramètres <sup>16</sup> de l'optimisateur de l'hyperparamètre « Nombre d'unités par couche LSTM »	Min_value	32
	max_value	512
	Step	32
Paramètres <sup>17</sup> de l'optimisateur de l'hyperparamètre « Taux de dropout »	Min_value	0.0
	max_value	0.5
	Step	0.1

#### 4. Résultats

Afin d'apprécier la performance des modèles de prévision et de permettre leur comparaison, trois mesures ont été sélectionnées : l'Erreur Absolue Moyenne (Mean Absolute Error, MAE), l'Erreur Quadratique Moyenne (Root Mean Square Error, RMSE) et l'Erreur Absolue Moyenne en Pourcentage (Mean Absolute Percentage Error, MAPE).

Les performances prédictives des modèles économétriques ainsi que le modèle de DL sont synthétisées dans les tableaux présentés ci-dessous :

<sup>15</sup> Le gradient est un vecteur qui indique la direction et l'amplitude (en multipliant le gradient par le taux d'apprentissage) par lesquelles il faut ajuster les poids du modèle pour réduire l'erreur.

<sup>16</sup> Les valeurs des paramètres ont été établies en s'appuyant sur le consensus dégagé par les travaux de recherche existants sur le sujet.

<sup>17</sup> Les valeurs des paramètres ont été établies en s'appuyant sur le consensus dégagé par les travaux de recherche existants sur le sujet.

	Modèles économétriques							Modèle de DL
Modèle	GARCH	EGARCH	GARCH-X	ARMAX-GARCH	EGARCH X	ARMAX-EGARCH	DCC-GARCH	LSTM
<b>Qualité prévisionnelle du rendement de 3 mois</b>								
RMSE	0.028408	0.028424	0.028177	0.027552	0.028506	0.027865	0.02654	0.0602
MAE	0.021761	0.021814	0.021704	0.21275	0.021923	0.021575	0.0245145	0.0460
MAPE	0.619168	0.620693	0.616667	0.604482	0.622727	0.612525	0.591458	1.32
<b>Qualité prévisionnelle du rendement de 1 an</b>								
RMSE	0.03136	0.031629	0.031798	0.031948	0.031815	0.031937	0.0245145	0.0885
MAE	0.024601	0.024601	0.024863	0.024908	0.024871	0.024906	0.0245145	0.0698
MAPE	0.781487	0.781493	0.78258	0.783834	0.782872	0.784188	0.7451525	2.18
<b>Qualité prévisionnelle du rendement de 2 ans</b>								
RMSE	0.043320	0.043321	0.302	0.023859	0.024	0.022922	0.0225202	0.0907
MAE	0.033242	0.033240	0.0233	0.018983	0.01514	0.014386	0.0225202	0.0692
MAPE	1.209181	1.209124	0.8415	0.687331	0.688	0.687311	0.622	2.58
<b>Qualité prévisionnelle du rendement de 5 ans</b>								
RMSE	0.047321	0.047322	0.030938	0.028004	0.027543	0.028091	0.0211765	0.0647
MAE	0.037161	0.037156	0.023576	0.021564	0.019847	0.021593	0.0211765	0.0503
MAPE	1.564119	1.564059	0.98101	0.90028	0.872919	0.9011747	0.852547	2.14
<b>Qualité prévisionnelle du rendement de 10 ans</b>								
RMSE	0.049278	0.0491218	0.0305	0.031815	0.030551	0.027536	0.026963	0.0746
MAE	0.038001	0.0379	0.022765	0.024871	0.022765	0.021009	0.026963	0.0587
MAPE	1.521816	1.581218	0.904	0.782872	0.9044143	0.785400	0.774154	2.38

## 5. Interprétations

Parmi les modèles économétriques, le DCC-GARCH se distingue, offrant les meilleures qualités prévisionnelles, et ce pour toutes les maturités. Ce résultat était prévisible. En effet, le DCC-GARCH, une extension des modèles GARCH au cadre multivarié, a été conçu spécifiquement pour capturer à la fois la volatilité conditionnelle<sup>18</sup>, le regroupement de volatilité<sup>19</sup> et les corrélations conditionnelles entre les différentes variables. Ainsi, par rapport aux modèles GARCH classiques qui supposent une structure de corrélation constante, DCC-GARCH offre l'option de considérer le mouvement des corrélations dans le temps et permet donc de mieux saisir la dynamique du marché financier.

<sup>18</sup> L'hétéroscédasticité est à l'origine du phénomène de regroupement de volatilité.

<sup>19</sup> Selon Dowd (2005), les modèles GARCH sont « tailormade for volatility clustering ».

Par ailleurs, nous remarquons que le modèle ARMAX-EGARCH offre la deuxième meilleure performance en termes de prévision.

En effet, le processus des rendements s'avère un processus dynamique qui est affecté, en plus de ses déterminants (composante X, dont les coefficients sont significatifs), par ses niveaux retardés (composantes AR, dont les coefficients sont significatifs). Par ailleurs, la significativité des coefficients afférents aux termes de la moyenne mobile (composante MA) indique que les chocs aléatoires passés ont un effet persistant sur la série (effet mémoire de choc). La modélisation ARMAX permet de capturer ces dynamiques.

De plus, nos résultats indiquent que le coefficient d'asymétrie du modèle EGARCH est significatif. Cela signifie que la volatilité exhibe un phénomène d'asymétrie, qui n'est pas capturé par les modèles GARCH classiques. En effet, une caractéristique souvent observée dans les séries financières est que la réponse de la volatilité aux chocs positifs et négatifs, de même ampleur, est asymétrique. Plus précisément, les chocs négatifs ont tendance à conduire à une volatilité ultérieure plus élevée que les chocs positifs de même ampleur. Ce phénomène est connu sous le nom « l'effet de levier ». Le modèle EGARCH est spécifiquement conçu pour capturer les asymétries et les effets de levier.

Par ailleurs, la supériorité des modèles GARCH avec caractéristiques (variables déterminantes) par rapport aux modèles simples est cohérent avec la littérature. Le marché financier constitue un écosystème interconnecté dans lequel les différentes variables interagissent de manière continue et complexe. Ces interactions engendrent une influence substantielle des variables macroéconomiques et financières sur la trajectoire future de la courbe des rendements. Nos résultats sont compatibles avec ceux de Vieira (2020) qui a démontré que l'inclusion de variables économiques a amélioré la qualité prévisionnelle des modèles.

Pour le LSTM, bien que ses caractéristiques suggèrent un potentiel de performance prédictive supérieur par rapport aux modèles économétriques, ce modèle a produit les prévisions les moins précises. Ces résultats sont compatibles avec ceux de Nunesa et al (2018) ; Castellani et Santos (2006) ainsi que Dunis et Morrison (2007). En effet, Castellani et Santos (2006) ont comparé les prévisions des réseaux de neurones avec celles des modèles économétriques pour la prévision des rendements obligataires d'Etat américaines en utilisant quatre indicateurs économiques, à savoir, le VIX, le Libor, le PMI et le CPI. Leurs résultats indiquent que les réseaux de neurones ne confèrent pas une qualité prévisionnelle meilleure par rapport aux modèles classiques. Les auteurs concluent que le paramétrage des modèles d'IA est une tâche ardue et coûteuse en termes de temps et de puissance des machines.

De la même manière, Kim et Won (2018) ont comparé les prévisions des modèles LSTM et GARCH pour les prix des actions et ont conclu que le LSTM ne fournit pas de meilleures performances. Rodrigues (2020) a également étudié la qualité prévisionnelle des réseaux de neurones et a conclu qu'elle n'est pas satisfaisante. Toutes ces études expliquent cette performance modeste par la difficulté de paramétrage des modèles de réseaux de neurones.

Bien que dans cette analyse nous avons utilisé un optimisateur pour la recherche des meilleurs paramètres du modèle (et non une recherche manuelle classique), cette approche, particulièrement coûteuse en termes de temps en raison des paramètres définis (max-value, min-value et step), n'a pas permis d'obtenir des résultats satisfaisants.

Le manque de travaux publiés dans ce domaine<sup>20</sup>, notamment pour le marché obligataire, a été une limite majeure pour notre étude<sup>21</sup>.

Finalement, il est important de souligner que, outre la complexité de son paramétrage, le modèle LSTM présente deux défis majeurs qu'il convient d'examiner avant de procéder à son application :

<sup>20</sup> Cette limite de manque de travaux a été mentionnée dans la majorité des papiers que nous avons analysés. Particulièrement, Nunesa et al, (2018) confirment que la courbe des rendements, un élément central des marchés financiers, est une classe d'actifs importante qui demeure relativement peu exploitée avec de le ML.

<sup>21</sup> Le code du modèle LSTM, avec tout le paramétrage effectué, a été développé exclusivement par l'auteur.

- Le temps d'entraînement long : l'entraînement sur de grands ensembles de données peut être très coûteux en termes de temps et nécessiter un matériel puissant.

- Le risque de surapprentissage : Ce phénomène se traduit par une adaptation excessive aux données d'entraînement, au détriment de la capacité de généralisation du modèle. Pour pallier ce problème, des techniques de régularisation, telles que le dropout, que nous avons intégrées dans notre travail, sont couramment utilisées.

### **Conclusion générale**

Nos résultats mettent en évidence la supériorité des modèles économétriques sur le modèle LSTM, ce dernier ayant généré les prévisions les moins précises. La performance modeste du LSTM peut être attribuée à la complexité inhérente à son paramétrage. L'ajustement des hyperparamètres pour un problème spécifique est un processus difficile, extrêmement coûteux en termes de temps et en ressources informatiques (Kim & Won, 2018 ; Rodrigues, 2020). Par ailleurs, parmi les modèles économétriques, le modèle DCC-GARCH s'est distingué en offrant les prévisions les plus précises. Sa capacité à capturer simultanément la volatilité conditionnelle et les corrélations conditionnelles entre les variables lui confère un avantage significatif sur les autres variantes de modèles GARCH, qui supposent des structures de corrélation statiques. Cette étude comparative souligne l'intérêt d'évaluer l'apport des approches basées sur l'IA en matière de performance prédictive, tout en mettant en évidence les limites et les défis associés à leur mise en œuvre.

De nombreuses pistes d'extension découlent de notre recherche, ouvrant la voie à des investigations futures. Une première suggestion consisterait à intégrer le modèle de Nelson-Siegel, afin d'enrichir la comparaison des performances des approches de prévision. Une seconde perspective d'approfondissement viserait l'optimisation de deux paramètres clés du modèle LSTM : le nombre de batchs et le taux d'apprentissage (dont la valeur a été sélectionnée par défaut). Une troisième possibilité résiderait dans l'introduction d'extensions avancées du modèle LSTM, telles que le LSTM bidirectionnel (BiLSTM) qui traite d'une manière bidirectionnelle les séquences de données.

## Références Bibliographiques

---

- Abad, P., Chuliá, H., & Gómez-Puig, M. (2010). EMU and European government bond market integration. *Journal of Banking & Finance*, <https://doi.org/10.1016/j.jbankfin.2009.10.009>
- Akram, T., & Das, A. (2014b). The determinants of long-term Japanese government bonds' low nominal yields. *Levy Economics Institute Working Paper No. 818* (October). Available at <http://www.levyinstitute.org/pubs/wp818.pdf>
- Akram, T., & Das, A. (2015a). Does Keynesian theory explain Indian government bond yields? *Levy Economics Institute Working Paper No. 834* (March). <http://www.levyinstitute.org/pubs/wp834.pdf>
- Akram, T., & Das, A. (2015b). A Keynesian explanation of Indian government bond yields. *Journal of Post Keynesian Economics*, 38(4), 565–587. <https://doi.org/10.1080/01603477.2015.1090294>
- Akram, T., & Das, A. (2017). The dynamics of government bond yields in the Euro Zone. *Annals of Financial Economics*, 12(3), 1750011. <https://doi.org/10.1142/S2010495217500117>
- Akram, T., & Das, A. (2017a). The long-run determinants of Indian government bond yields. *Levy Economics Institute Working Paper No. 881* (January). <http://www.levyinstitute.org/pubs/wp881.pdf>
- Akram, T., & Das, A. (2017b). The dynamics of government bond yields in the euro zone. *Levy Economics Institute Working Paper No. 889* (May). <http://www.levyinstitute.org/pubs/wp889.pdf>
- Alexopoulou, I., Bunda, I., & Ferrando, A. (2010). Determinants of government bond spreads in new EU countries. *Eastern European Economics*. <https://doi.org/10.2753/EEE0012-8775480501>
- Aman, A., Isa, M. Y., & Naim, A. M. (2023). The role of macroeconomic and financial factors in bond market development in selected countries. *Global Business Review*, 24(4), 626–641. <https://doi.org/10.1177/0972150920907206>
- Andersson, O., & Ekman, N. (2014). Long-term government bond yields and macroeconomic variables (Master's thesis, Lund University, School of Economics and Management, Department of Economics). <https://lup.lub.lu.se/student-papers/record/3914314>
- Antony, J. M., & Natarajan, S. (2024). Neural network and machine learning use cases: Indian bond market predictions. *The Economics and Finance Letters*, 11(1), 57-79. <https://doi.org/10.18488/29.v11i1.3667>
- Ardagna, S., Caselli, F., & Lane, T. (2007). Fiscal discipline and the cost of public debt service: Some estimates for OECD countries. *The B.E. Journal of Macroeconomics*, 7(1), 1-33.
- Arrieta-Ibarra, I., & Lobato, I. N. (2015). Testing for predictability in financial returns using statistical learning procedures. *Journal of Time Series Analysis*, 36(5), 672–686.
- Asgharian, H., Christiansen, C., & Hou, A. J. (2015). Effects of macroeconomic uncertainty on the stock and bond markets. *Finance Research Letters*, 13, 10-16. <https://doi.org/10.1016/j.frl.2015.03.008>
- Aßmann, C., & Boysen-Hogrefe, J. (2012). Determinants of government bond spreads in the euro area: In good times as in bad. *Empirica*, 39(3), 341–356. <https://doi.org/10.1007/s10663-012-9172-6>
- Baker, J., Carreras, O., Kirby, S., & Meaning, J. (2016). The fiscal and monetary determinants of sovereign bond yields in the Euro Area (No. 466). *National Institute of Economic and Social Research*.
- Baldacci, E., & Kumar, M. (2010). Fiscal deficits, public debt, and sovereign bond yields. *IMF Working Paper No. 10/184*. Available at <http://www.imf.org/external/pubs/ft/wp/2010/wp10184.pdf>
- Becker, B., & Ivashina, V. (2015). Reaching for yield in the bond market. *The Journal of Finance*, 70(5), 1863–1902. <https://doi.org/10.1111/jofi.12275>
- Bekaert, G., Engstrom, E., & Ermolov, A. (2021). Macro risks and the term structure of interest rates. *Journal of Financial Economics*. <https://doi.org/10.1016/j.jfineco.2021.03.011>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer-Verlag. ISBN 978-0-387-31073-2.
- Blot, C., & Hubert, P. (2016). Causes et conséquences des taux d'intérêt négatifs. *Revue de l'OFCE*, 148, 11-38. <https://doi.org/10.3917/reof.148.0011>

- Boeck, M., & Feldkircher, M. (2021). The Impact of Monetary Policy on Yield Curve Expectations. *Economic Behavior and Organization*, 191, 887-901. <https://www.sciencedirect.com/science/article/pii/S0167268121004297>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Bordo, M. D., & Haubrich, J. G. (2021). Some international evidence on the causal impact of the yield curve. *Finance Research Letters*, March, 102116. <https://doi.org/10.1016/j.frl.2021.102116>
- Borio, C., Ebbesen, J., Galati, G., & Heath, A. (2008). FX reserve management: Elements of a framework (BIS Papers No. 38). Bank for International Settlements. <https://www.bis.org>
- Brennan, M., Kobor, A., & Rustaman, V. (2011). Diversifying market and default risk in high grade sovereign bond portfolios. In *Portfolio and risk management for central banks and sovereign wealth funds: Proceedings of a joint conference organised by the BIS, the ECB and the World Bank in Basel, 2–3 November 2010*. Bank for International Settlements. <https://www.bis.org>
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to time series and forecasting*. Springer Texts in Statistics. Springer International Publishing. <https://doi.org/10.1007/978-3-319-29854-2>
- Brooks, C. (2014). *Introductory Econometrics for Finance*. United Kingdom: Cambridge University Press.
- Brownlee, J. (2018). Long short-term memory networks with Python: Develop sequence prediction models with deep learning. *Machine Learning Mastery*.
- Brownlee, J. (2022). Time series prediction with LSTM recurrent neural networks in Python with Keras. <https://machinelearningmastery.com/time-series-prediction-lstm-recurrent-neural-networks-python-keras/>
- Caldeira, J., & Torrent, H. (2017). Forecasting the US term structure of interest rates using nonparametric functional data analysis. *Journal of Forecasting*, 36(1), 56–73.
- Cao, Y. (2023). Forecast yield curve of China's government bond with machine learning. SSRN. <https://ssrn.com/abstract=4533382>
- Cardon, P., & Coche, J. (2004). Strategic asset allocation for foreign exchange reserves. In C. Bernadell, P. Cardon, J. Coche, F. X. Diebold, & S. Manganelli (Eds.), *Risk management for central bank foreign reserves* (pp. 13-29). European Central Bank.
- Castellani, M., & dos Santos, E. A. (2006). Forecasting long-term government bond yields: An application of statistical and AI models. ISEG, Departamento de Economia, 1–34.
- Chen, K., Zhou, Y., & Da, F. (2015). A LSTM-based method for stock returns prediction: A case study of China stock market. In *2015 IEEE International Conference on Big Data (Big Data)*.
- Chirinos-Leañez, A., & Pagliacci, C. (2015). Macroeconomic Shocks And The Forward Yield Curve: How Important Is Monetary Policy? *Macroeconomics and Finance in Emerging Market Economies*. [https://journals.scholarsportal.info/details/17520843/v08i0003/201\\_msatfychiimp.xml&sub=all](https://journals.scholarsportal.info/details/17520843/v08i0003/201_msatfychiimp.xml&sub=all)
- CHRISTOFER NORDSTRÖM (2021), « DCC-GARCH Estimation »
- Chuku, C., Simpasa, A., & Oduor, J. (2019). Intelligent Forecasting Of Economic Growth For African Economies: Artificial Neural Networks Versus Time Series and Structural Econometric Model. *International Economics*, 159, 74-93. <https://www.sciencedirect.com/science/article/pii/S2110701718301185>
- Claessens, S., & Kreuser, J. (2004). A framework for strategic foreign reserves risk management. In C. Bernadell, P. Cardon, J. Coche, F. X. Diebold, & S. Manganelli (Eds.), *Risk management for central bank foreign reserves* (pp. 47-291). European Central Bank.
- Claessens, S., & Kreuser, J. (2007). Strategic foreign reserves risk management: Analytical framework. *Annals of Operations Research*, 152, 79–113. <https://doi.org/10.1007/s10479-006-0124-6>
- Claessens, S., Klingebiel, D., & Schmukler, S. (2003). Government bonds in domestic and foreign currency: The role of macroeconomic and institutional factors. World Bank. <https://doi.org/10.2139/ssrn.1070291>

- Claessens, S., Kreuser, J., & Wets, R. (2000, April). Strategic risk management for developing countries: The Colombia case study (Presented at the second Inter-regional Debt Management Conference, Geneva). The World Bank.
- Coche, J., Koivu, M., Nyholm, K., & Poikonen, V. (2006). Foreign reserves management subject to a policy objective (Working Paper Series No. 624). European Central Bank. <http://www.ecb.int>
- Culurciello, E. (2018). The fall of RNN / LSTM. Towards Data Science. <https://towardsdatascience.com/the-fall-of-rnn-lstm>
- Di Persio, L., & Honchar, O. (2016a). Artificial neural networks architectures for stock price prediction: Comparisons and applications. *International Journal of Circuits, Systems and Signal Processing*, 10, 403–413.
- Diebold, F., Rudebusch, G., & Aruoba, S. (2006). The Macroeconomy And The Yield Curve: A Dynamic Latent Factor Approach. *Journal of Econometrics*, 131, 309-338. <https://www.sas.upenn.edu/~fdiebold/papers/paper55/DRAfinal.pdf>
- Ding, G., & Qin, L. (2019). Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 11(6), 1307–1317. <https://doi.org/10.1007/s13042-019-01041-1>
- Dunis, C. L., & Morrison, V. (2007). The economic value of advanced time series methods for modelling and trading 10-year government bonds. *European Journal of Finance*, 13(4), 333–352.
- Elisabeth Orskaug (2009), “Multivariate DCC-GARCH Model”
- Enders, W. (2015). *Applied Econometrics Times Series*. United States of America: John Wiley & Sons.
- Fabozzi, F. J., Mann, S. V., & Fabozzi, F. (2021). *The handbook of fixed income securities* (9th ed.). McGraw-Hill. ISBN 978-1-260-47390-2.
- Fatmawatie, N., Endri, E., & Husein, D. (2024). Macroeconomic factors and government bond yield in Indonesia. *Public and Municipal Finance*, 13(1), 95-105. [https://doi.org/10.21511/pmf.13\(1\).2024.08](https://doi.org/10.21511/pmf.13(1).2024.08)
- 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>.
- Gadre, V. (2023). Recurrent neural networks: A beginner’s guide. <https://vijaygadre.medium.com/recurrent-neural-networks-a-beginners-guide-16333bd2eeb1>
- García López, G. I., Jiménez Padrón, R., & San Martín Kuri Breña, A. (2020). The strategic asset allocation framework of Banco de México. In J. Bjorheim (Ed.), *Asset management at central banks and monetary authorities: New practices in managing international foreign exchange reserves* (pp. 241-305). Springer Nature Switzerland AG. <https://doi.org/10.1007/978-3-030-43457-1>
- García-Pulgarín, J. D., Gómez-Restrepo, J., & Vela-Barón, D. (2015). An asset allocation framework with tranches for foreign reserves. *Borradores de Economía*, 899. Banco de la República. <https://www.banrep.gov.co/en/borradores-de-economia>
- Gill, N. (2018). A research on Eurozone bond market and determinants of sovereign bond yields. *Journal of Financial Risk Management*, 7, 174–190. <https://doi.org/10.4236/jfrm.2018.72012>
- Gogas, P., Papadimitriou, T., Matthaïou, M., & Chrysanthidou, E. (2015). Yield curve and recession forecasting in a machine learning framework. *Computational Economics*, 45, 635-645. <https://doi.org/10.1007/s10614-014-9432-0>
- Gogas, P., Papadimitriou, T., Matthaïou, M., & Chrysanthidou, E. (2015). Yield curve and recession forecasting in a machine learning framework. *Computational Economics*, 45(4), 635–645.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. ISBN 978-0-262-03561-3. <https://www.deeplearningbook.org/>.
- Götze, T., Gürtler, M., & Witowski, E. (2023). Forecasting accuracy of machine learning and linear regression: Evidence from the secondary CAT bond market. *Journal of Business Economics*, 1-32. <https://doi.org/10.1007/s11573-023-01138-8>



- Gruber, J. W., & Kamin, S. B. (2012). Fiscal positions and government bond yields in OECD countries. *Journal of Money, Credit, and Banking*. <https://doi.org/10.1111/j.1538-4616.2012.00544.x>
- Gu, S., Kelly, B. T., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223–2273. <https://doi.org/10.1093/rfs/hhaa009>.
- Hiransha, M., Gopalakrishnan, E., Vijay, M., & Soman, K. (2018). NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, 132, 1351–1362. <https://www.sciencedirect.com/science/article/pii/S1877050918307828>
- Ho, C. (2004). Foreign reserves risk management in Hong Kong. In C. Bernadell, P. Cardon, J. Coche, F. X. Diebold, & S. Manganelli (Eds.), *Risk management for central bank foreign reserves* (pp. 291-319). European Central Bank.
- Hsing, Y. (2015). Determinants of the government bond yield in Spain: A loanable funds model. *International Journal of Financial Studies*, 3(3), 342-350. <https://doi.org/10.3390/ijfs3030342>
- Jalles, J. T. (2019). How do macroeconomic fundamentals affect sovereign bond yields? New evidence from European forecasts. *CESifo Economic Studies*, <https://doi.org/10.1093/cesifo/ify025>
- Jammazi, R., Ferrer, R., Jareño, F., & Hammoudeh, S. (2017). Main Driving Factors Of The Interest Rate-Stock Market Granger Causality. *International Review of Financial Analysis*, 52, 260-280. <https://www.sciencedirect.com/science/article/pii/S1057521917300790>
- Johnson-Calari, J., & Strauss-Kahn, I. (2020). Good governance: Principles, pitfalls, and best practice. In J. BJORHEIM (Ed.), *Asset management at central banks and monetary authorities: New practices in managing international foreign exchange reserves* (pp. 305-323). Springer Nature Switzerland AG. <https://doi.org/10.1007/978-3-030-43457-1>
- Joyce, M., Lasaosa, A., Stevens, I., & Tong, M. (2010). The financial market impact of quantitative easing. *Bank of England Working Paper*, No. 393.
- Kanapeckas, J. (2020). Central Bank of Lithuania: Asset allocation in a risk parity framework. In *Asset management at central banks and monetary authorities: New practices in managing international foreign exchange reserves*. Springer. <https://doi.org/10.1007/978-3-030-43457-1>
- Koroleva, E., & Kopeykin, M. (2022). Understanding of macro factors that affect yield of government bonds. *Risks*, 10(8), 166. <https://doi.org/10.3390/risks10080166>
- Kwamuma, P., & Weda, C. (2019). Influence of macroeconomic variables on government bond performance at Nairobi Securities Exchange in Kenya. *The Strategic Journal of Business & Change Management*, 6(2), 1012–1029. [www.strategicjournals.com](http://www.strategicjournals.com)
- León, C., & Vela, D. (2011). Foreign reserves' strategic asset allocation (Borradores de Economía No. 645). Banco de la República.
- Li, Z., Wang, B., & Chen, Y. (2024). Incorporating economic indicators and market sentiment effect into US Treasury bond yield prediction with machine learning. *Journal of Infrastructure, Policy and Development*, 8(9), 7671. <https://doi.org/10.24294/jipd.v8i9.7671>
- Liu, Q., Tao, Z., Tse, Y., & Wang, C. (2022). Stock Market Prediction With Deep Learning: The Case Of China. *Finance Research Letters*, 46. <https://www.sciencedirect.com/science/article/pii/S1544612321002762>
- Lowry, C. (2022). How Inflation Affects Currency And Interest Rates. <https://www.westernunion.com/blog/en/us/how-inflation-affects-currency-and-interestrates>
- Magnus, H. (2017). On stock return prediction with LSTM networks. Department of Economics, Lund University.
- Maia, I. R. D. (2020). Central Bank of Brazil: Investment decision-making in an integrated risk management framework. In J. BJORHEIM (Ed.), *Asset management at central banks and monetary authorities: New practices in managing international foreign exchange reserves* (pp. 323-335). Springer Nature Switzerland AG. <https://doi.org/10.1007/978-3-030-43457-1>
- Martin, D., Póczos, B., & Hollifield, B. (2014). Machine learning-aided modeling of fixed income instruments.

- Mihelja Žaja, M., Jakovčević, D., & Višić, L. (2018). Determinants of the government bond yield: Evidence from a highly euroised small open economy. *International Journal of Economic Sciences*, 7(2), 87-106. <https://doi.org/10.20472/ES.2018.7.2.005>
- Mun, W. C. P., & Soong, V. (2021). Forecasting yield curve with macro-driven models: A comparison between machine learning and traditional statistical approaches.
- Nandakumar, R., K., Uttamraj, K., Vishal, & Lokeswari, Y. V. (2018). Stock price prediction using Long Short-Term Memory. *International Research Journal of Engineering and Technology (IRJET)*.
- Nguyen, H. L. T., & Nguyen, P. A. (2022). The impacts of fiscal and macroeconomic factors on Vietnam government bond yield. *International Journal of Economics and Finance*, 14(8), 23. <https://doi.org/10.5539/ijef.v14n8p23>
- Nugée, J. (2020). Modern central bank reserves management: Introduction and overview. In *Asset management at central banks and monetary authorities: New practices in managing international foreign exchange reserves*. <https://doi.org/10.1007/978-3-030-43457-1>
- Nunes, M. C. M. (2022). Machine learning in fixed income markets: Forecasting and portfolio management (Doctoral thesis, University of Southampton). [https://eprints.soton.ac.uk/467523/1/Final\\_Thesis\\_unsigned.pdf](https://eprints.soton.ac.uk/467523/1/Final_Thesis_unsigned.pdf)
- Nunes, M., Gerding, E., McGroarty, F., & Niranjana, M. (2018). Artificial neural networks in fixed income markets for yield curve forecasting. SSRN. <https://ssrn.com/abstract=3144622>
- Nunes, M., Gerding, E., McGroarty, F., & Niranjana, M. (2019b). The memory advantage of long short-term memory networks for bond yield forecasting. *International Conference on Forecasting Financial Markets, FFM*. <https://doi.org/10.2139/ssrn.3415219>.
- Obalade, A. A., Khumalo, Z., Maistry, S., Naidoo, M., Thwala, N., & Muzindutsi, P. F. (2023). The macroeconomic determinants of the South African bond performance under different regimes. *Review of Integrative Business and Economics Research*, 12(1), 92.
- Olah, C. (2015). Understanding LSTM networks. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Oosterlaken, J. (2020). Predicting the US Treasury yields using machine learning techniques.
- Papaianou, M., Al-Hassan, A., & Farahmand, P. (2014). Revised guidelines for foreign exchange reserve management. *International Monetary Fund*. <https://www.elibrary.imf.org>
- Pappas, A., & Kostakis, I. (2020). The driving factors of EMU government bond yields: The role of debt, liquidity, and fiscal councils. *International Journal of Financial Studies*, 8(3), 53. <https://doi.org/10.3390/ijfs8030053>
- Poghosyan, T. (2012). Long-run and short-run determinants of sovereign bond yields in advanced economies. *IMF Working Paper No. WP/12/271*. <https://doi.org/10.5089/9781475503287.001>
- Poghosyan, T. (2014). Long-run and short-run determinants of sovereign bond yields in advanced economies. *Economic Systems*, 38(1), 100–114. <https://doi.org/10.1016/j.ecosys.2013.07.008>
- Pozzi, L., & Wolswijk, G. (2012). The time-varying integration of euro area government bond markets. *European Economic Review*, 56(1), 36-53. <https://doi.org/10.1016/j.eurocorev.2011.05.006>
- Puglia, M., & Tucker, A. (2020). Machine Learning, The Treasury Yield Curve And Recession Forecasting. *Finance and Economics Discussion Series*. <https://www.federalreserve.gov/econres/feds/machine-learning-the-treasury-yield-curveand-recession-forecasting.htm>
- Putnam, B. H. (2004). Thoughts on investment guidelines for institutions with special liquidity and capital preservation requirements. In C. Bernadell, P. Cardon, J. Coche, F. X. Diebold, & S. Manganelli (Eds.), *Risk management for central bank foreign reserves*. European Central Bank.
- Raschka, S., & Mirjalili, V. (2019). Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. In (pp. 71 –83): Packt Publishing Ltd.
- Romanyuk, Y. (2010). Liquidity, risk, and return: Specifying an objective function for the management of foreign reserves (Discussion Paper No. 2010-13). Bank of Canada. <https://www.bankofcanada.ca>

- Romanyuk, Y. (2012). Liquidity, risk, and return: Specifying an objective function for the management of foreign reserves. *Applied Stochastic Models in Business and Industry*, 28(2), 175–193. <https://doi.org/10.1002/asmb.1921>
- Rubin, T. (2020). Yield Curve And Macroeconomy Interaction: Evidence From The NonParametric Functional Lagged Regression Approach. Working Paper. <https://arxiv.org/abs/2007.02763#>
- Rudebusch, G., & Wu, T. (2004). A Macro-Finance Model Of The Term Structure, Monetary Policy, And The Economy. Federal Reserve Bank of San Francisco Working Paper. <https://www.frbsf.org/economic-research/files/wp03-17bk.pdf>
- Sambasivan, R., & Das, S. (2017, June). A statistical machine learning approach to yield curve forecasting [Conference paper]. In 2017 International Conference on Computational Intelligence in Data Science (ICCIDS). IEEE. <https://doi.org/10.1109/ICCIDS.2017.8272667>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Schuknecht, L., Von Hagen, J., & Wolswijk, G. (2009). Government risk premiums in the bond market: EMU and Canada. *European Journal of Political Economy*, 25(3), 371–384. <https://doi.org/10.1016/j.ejpoleco.2009.02.004>
- 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, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Shareef, H., & Shijin, S. (2017). The Term Structure Of Interest Rates And Macroeconomic Factors: Evidence From Indian Financial Market. *Borsa Istanbul Review*, 17. <https://www.sciencedirect.com/science/article/pii/S221484501630120X>
- Shu, L., & Chou, J.-K. (2021). Using deep learning techniques to predict 10-year US Treasury yield. In Proceedings of the 2021 11th International Conference on Information Science and Technology (ICIST). <https://doi.org/10.1109/icist52614.2021.9440560>
- Sihombing, P., Santoso, E., & Hariyanti, D. (2023). Macroeconomic variables effect on 10-year tenor government bonds yield. *Research of Economics and Business*, 1(2), 57–67. <https://doi.org/10.58777/reb.v1i2.83>
- Simeon, K. (2022). Inflation Forecasting In Côte D'Ivoire A Comparative Analysis Of The Arima, Holt-Winters, And LSTM Models. Munich Personal RePEc Archive. <https://www.researchgate.net/profile/KoffiSimeon/publication/362420714>
- Sims, C. A. (2012). Gaps in the institutional structure of the euro area. <http://sims.princeton.edu/yftp/EuroGaps/EuroGaps.pdf>
- Tjandrasa, B. B., Siagian, H., & Jie, F. (2020). The macroeconomic factors affecting government bond yield in Indonesia, Malaysia, Thailand, and the Philippines. *Investment Management and Financial Innovations*, 17(3), 111–121. [https://doi.org/10.21511/imfi.17\(3\).2020.09](https://doi.org/10.21511/imfi.17(3).2020.09)
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929–5955. <https://doi.org/10.1007/s10462-020-09838-1>
- Vieira, T. A. R. de S. (2020). Forecasting sovereign bonds markets using machine learning: Forecasting the Portuguese government bond using machine learning approach.
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia Computer Science*, 167, 599–606. <https://doi.org/10.1016/j.procs.2020.03.326>
- Wang, J., Hong, S., Dong, Y., et al. (2024). Predicting stock market trends using LSTM networks: Overcoming RNN limitations for improved financial forecasting. *Journal of Computer Science and Software Applications*, 4(3), 1–7. <https://doi.org/10.5281/ZENODO.12200708>
- Weng, B. (2017). Application of machine learning techniques for stock market prediction. Faculty of Auburn University.
- Xu, K., Cheng, Y., Long, S., et al. (2024). Advancing financial risk prediction through optimized LSTM model performance and comparative analysis. <https://arxiv.org/abs/2405.20603>

- Ying, J.-C., Wang, Y.-B., Chang, C.-K., et al. (2019). DeepBonds: A deep learning approach to predicting United States Treasury yield. In 2019 Twelfth International Conference on Ubi-Media Computing (Ubi-Media). <https://doi.org/10.1109/ubi-media.2019.00055>
- Zhang, Z., Chau, F., & Xie, L. (2012). Strategic asset allocation for central bank's management of foreign reserves: A new approach (MPRA Paper No. 43654). Durham University Business School. <https://mpra.ub.uni-muenchen.de/43654/>
- Zhou, J., Chen, C., Li, L., Zhang, Z., & Zheng, X. (2022). FinBrain 2.0: When finance meets trustworthy AI. *Frontiers of Information Technology & Electronic Engineering*, 23(12), 1747-1764. <https://doi.org/10.1631/fitee.2200039>
- Zhou, S. (2021). Macroeconomic determinants of long-term sovereign bond yields in South Africa. *Cogent Economics & Finance*, 9(1), 1929678. <https://doi.org/10.1080/23322039.2021.1929678>

### **Rapports:**

- Bank for International Settlements. (2019). Triennial central bank survey of foreign exchange and over-the-counter (OTC) derivatives markets in 2019. Bank for International Settlements. <https://www.bis.org/statistics/rpfx19.htm>
- World Bank. (2023). Reserve management survey report: The fourth edition: Insights into public asset management. World Bank Treasury. <https://www.worldbank.org>

### **Cours:**

- Daouas, P. (2023). Cours de gestion obligataire. Institut de Financement du Développement du Maghreb Arabe (IFID).

### **Sites internet:**

- European Central Bank. Site officiel. <https://www.ecb.europa.eu/home/html/index.en.html>
- Federal Reserve Economic (FRED) Data. <https://fred.stlouisfed.org/>
- Eurostat. (n.d.). <https://ec.europa.eu/eurostat/en/>
- The Royal Mint. (n.d.). Site officiel. <https://www.royalmint.com/>
- Banque Centrale de Tunisie. Site officiel. <https://www.bct.gov.tn/bct/siteprod/index.jsp>

**Annexe n°1 : Désagrégation temporelle de l'inflation**

```

if (!requireNamespace("readxl", quietly = TRUE)) {install.packages("readxl")}
if (!requireNamespace("tempdisagg", quietly = TRUE)) {install.packages("tempdisagg")}
if (!requireNamespace("writexl", quietly = TRUE)) {install.packages("writexl")}
if (!requireNamespace("lubridate", quietly = TRUE)) {install.packages("lubridate")}
if (!requireNamespace("zoo", quietly = TRUE)) {install.packages("zoo")}
if (!requireNamespace("tsbox", quietly = TRUE)) {install.packages("tsbox")}
if (!requireNamespace("xts", quietly = TRUE)) {install.packages("xts")}
library(readxl)
library(tempdisagg)
library(writexl)
library(lubridate)
library(zoo)
library(tsbox)
library(xts)
inflation_data <- read_excel("C:\\Users\\chema\\Desktop\\inflation EUR.xlsx")
colnames(inflation_data) <- c("Dates", "Inflation")
inflation_data$Dates <- paste0(inflation_data$Dates, "-01")
inflation_data$Dates <- ymd(inflation_data$Dates)
if (any(is.na(inflation_data$Dates))) {stop("Date conversion failed. Please check the format of your
date column.")}
inflation.ts <- zoo(inflation_data$Inflation, order.by = inflation_data$Dates)
update.packages("tempdisagg")
m.d.inflation <- td(inflation.ts, to = "daily", conversion = "average")
daily_inflation <- predict(m.d.inflation)
daily_dates <- seq(from = start(daily_inflation), to = end(daily_inflation), by = "day")
daily_inflation_df <- data.frame(Dates = daily_dates, Inflation = as.numeric(daily_inflation))
write_xlsx(daily_inflation_df, "C:\\Users\\chema\\Desktop\\Inflation EUR daily.xlsx")

```

**Annexe n°2 : Désagrégation temporelle de la dette gouvernementale**

```

if (!requireNamespace("readxl", quietly = TRUE)) {install.packages("readxl")}
if (!requireNamespace("tempdisagg", quietly = TRUE)) {install.packages("tempdisagg")}
if (!requireNamespace("writexl", quietly = TRUE)) {install.packages("writexl")}
if (!requireNamespace("lubridate", quietly = TRUE)) {install.packages("lubridate")}
if (!requireNamespace("zoo", quietly = TRUE)) {install.packages("zoo")}
if (!requireNamespace("tsbox", quietly = TRUE)) {install.packages("tsbox")}
if (!requireNamespace("xts", quietly = TRUE)) {install.packages("xts")}
library(readxl)
library(tempdisagg)
library(writexl)
library(lubridate)
library(zoo)
library(tsbox)

```

```

library(xts)
GOV_data <- read_excel("C:\\Users\\chema\\Desktop\\govdata.xlsx")
colnames(GOV_data) <- c("Dates", "GOV ")
GOV_data$Dates <- paste0(GOV_data$Dates, "-01")
GOV_data$Dates <- ymd(GOV_data$Dates)
GOV.ts <- zoo(GOV_data$`Gov`, order.by = GOV_data$Dates)
m.d.GOV <- td(GOV.ts, to = "daily", conversion = "average")
daily_GOV <- predict(m.d.GOV)
daily_dates <- seq(from = start(daily_GOV), to = end(daily_GOV), by = "day")
daily_GOV_df <- data.frame(Dates = daily_dates, `Gov` = as.numeric(daily_GOV))
write_xlsx(daily_GOV_df, "C:\\Users\\chema\\Desktop\\gov daily.xlsx")

```

### Annexe n°3 : Le code du modèle LSTM

```

!pip install tensorflow
!pip install keras-tuner
import tensorflow as tf
import keras_tuner
keras = tf.keras

import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
from sklearn.model_selection import train_test_split
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
import keras_tuner
from kerastuner.tuners import RandomSearch
import matplotlib.pyplot as plt
import matplotlib.pyplot as plt

file_path = r'C:\Users\chema\Desktop\data complete 1y.xlsx'
data = pd.read_excel(file_path)
data['DATE']=pd.to_datetime(data['DATE'])
data.set_index('DATE',inplace=True)
data.head()

features = data.drop('Yield 1y', axis=1)
target = data['Yield 1y']
target_scaler = MinMaxScaler(feature_range=(0, 1))
target_scaled = target_scaler.fit_transform(target.values.reshape(-1, 1))

scaler = MinMaxScaler(feature_range=(0, 1))
features_scaled = scaler.fit_transform(features)

features_scaled_df = pd.DataFrame(features_scaled, columns=features.columns)
features_scaled_df.index = data.index

def create_sequences(features, target, n_steps):
    X, y = [], []
    for i in range(len(features) - n_steps):
        X.append(features[i:(i + n_steps)].values)

```

```

        y.append(target[i + n_steps])
    return np.array(X), np.array(y)
n_steps = 10
X, y = create_sequences(features_scaled_df, target_scaled, n_steps)

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, shuffle=False)
X_val, X_test, y_val, y_test = train_test_split(X_test, y_test, test_size=0.5, shuffle=False)

def build_lstm_model(hp):
    model = Sequential()
    model.add(Input(shape=(X_train.shape[1], X_train.shape[2])))
    model.add(LSTM(units=hp.Int('units', min_value=32, max_value=512, step=32)))
    model.add(Dropout(rate=hp.Float('dropout', min_value=0.0, max_value=0.5, step=0.1)))
    model.add(LSTM(units=hp.Int('units_2', min_value=32, max_value=512, step=32)))
    model.add(Dropout(rate=hp.Float('dropout_2', min_value=0.0, max_value=0.5, step=0.1)))
    model.add(Dense(1, activation = 'relu'))
    model.compile(optimizer=hp.Choice('optimizer', ['adam', 'rmsprop']), loss='mean_squared_error')
    return model

import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Input, LSTM, Dropout, Dense
from keras_tuner import RandomSearch
tuner = RandomSearch( build_lstm_model, objective='val_loss', max_trials=10,
executions_per_trial=1, directory='my_dir', project_name='lstm_tuning')

tuner.search(X_train, y_train, epochs=50, validation_data=(X_val, y_val), batch_size=32)
best_hps = tuner.get_best_hyperparameters(num_trials=1)[0]

model = tuner.hypermodel.build(best_hps)
print("Best hyperparameters:")
print("Units:", best_hps.get('units'))
print("Dropout Rate:", best_hps.get('dropout'))
print("Units 2:", best_hps.get('units_2'))
print("Dropout Rate 2:", best_hps.get('dropout_2'))
print("Optimizer:", best_hps.get('optimizer'))

model.fit(X_train, y_train, epochs=50, validation_data=(X_val, y_val), batch_size=32)

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
y_full_pred_scaled = model.predict(X)
y_full_pred_rescaled = target_scaler.inverse_transform(y_full_pred_scaled)
y_full_actual_rescaled = target_scaler.inverse_transform(target_scaled)
results_df = pd.DataFrame({
    'Date': features_scaled_df.index[n_steps:],
    'Actual': y_full_actual_rescaled[n_steps:].flatten(),
    'Predicted': y_full_pred_rescaled.flatten()
}).set_index('Date')
test_dates = features_scaled_df.index[-len(y_test):]
results_test_df = results_df[results_df.index.isin(test_dates)]

```

```
import numpy as np
MSE = np.mean((results_test_df['Predicted'] - results_test_df['Actual']) ** 2)
RMSE = np.sqrt(MSE)
MAE = np.mean(np.abs(results_test_df['Predicted'] - results_test_df['Actual']))
MAPE = np.mean(np.abs((results_test_df['Predicted'] - results_test_df['Actual']) /
results_test_df['Actual'])) * 100
print(f"Mean Squared Error (MSE): {MSE:.4f}")
print(f"Root Mean Squared Error (RMSE): {RMSE:.4f}")
print(f"Mean Absolute Error (MAE): {MAE:.4f}")
print(f"Mean Absolute Percentage Error (MAPE): {MAPE:.2f}%")
```

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
lstm_layer = model.layers[0]
weights = lstm_layer.get_weights()[0]
weights_normalized = np.abs(weights) / np.sum(np.abs(weights))
print("Sum of normalized weights:", np.sum(weights_normalized))
feature_importance = np.mean(weights_normalized, axis=1)
feature_importance_percentage = feature_importance * 100
feature_names = list(data.columns[1:])
feature_importance_df = pd.DataFrame({'Feature': feature_names, 'Importance (%)':
feature_importance_percentage})
feature_importance_df.sort_values('Importance (%)', inplace=True, ascending=False)
print("Feature Importance Analysis (%):")
print(feature_importance_df)
plt.figure(figsize=(10, 6))
plt.barh(feature_importance_df['Feature'], feature_importance_df['Importance (%)'], color='skyblue')
plt.xlabel('Normalized Importance (%)')
plt.ylabel('Feature')
plt.title('Feature Importance Analysis for LSTM Model')
plt.gca().invert_yaxis()
plt.show()
```



**Annexe n°4 : Les statistiques descriptives des variables**

	Mean	Median	Maximum	Minimum	Std, Dev	Skewness	Kurtosis	CV	Jarque-Bera	Probability
YIELD3M	0,189	-0,265	3,913	-0,930	1,305	1,808	5,034	6,913	2611,235	0,000
YIELD1YEAR	0,205	-0,253	3,612	-0,913	1,263	1,538	4,061	6,163	1611,269	0,000
YIELD2YEARS	0,229	-0,194	3,257	-0,971	1,176	1,260	3,298	5,135	980,386	0,000
YIELD5YEARS	0,545	0,116	2,962	-0,996	1,116	0,641	2,030	2,047	393,466	0,000
YIELD_10YEARS	1,137	0,757	3,745	-0,815	1,185	0,278	1,792	1,042	269,453	0,000
VSTOXX	18,086	16,270	82,690	9,140	6,938	2,506	14,788	0,384	24900,370	0,000
GOLD_GROWTH <sup>22</sup>	0,025	0,047	6,734	-8,730	0,958	-0,388	9,064	38,055	5689,109	0,000
MSFXEURINDEX	0,851	0,875	1,039	0,672	0,077	-0,373	2,139	0,090	196,898	0,000
M2_GROWTH <sup>23</sup>	0,017	0,014	0,328	-0,108	0,023	2,439	24,738	1,401	75301,110	0,000
INFLATION	2,207	1,594	10,697	-0,650	2,337	1,797	5,917	1,059	3251,295	0,000
EURIBOR3M	0,497	-0,019	4,002	-0,605	1,308	1,622	4,412	2,635	1899,189	0,000
EURIBOR12M	0,776	0,170	4,228	-0,518	1,353	1,254	3,307	1,744	969,195	0,000
EESWE5BGN_CURRENCY	0,595	0,124	3,250	-0,828	1,115	0,927	2,533	1,873	556,340	0,000
EESWE2BGN_CURRENCY	0,365	-0,192	3,710	-0,824	1,235	1,432	3,655	3,389	1314,261	0,000
EESWE10BGN_CURRENCY	1,066	0,711	3,321	-0,638	1,059	0,430	1,993	0,993	266,846	0,000

<sup>22</sup> Nous désignons par GRWOTH la différence logarithmique de la variable brute.

<sup>23</sup> Nous désignons par GRWOTH la différence logarithmique de la variable brute.

Annexe n°5 : Test de Racine Unitaire

Variable	Test de racine unitaire ADF <i>Séries en niveau</i>		Test de racine unitaire ADF <i>Séries en différence première</i>		Test de racine unitaire ZA <i>Séries en niveau</i>		Test de racine unitaire ZA <i>Séries en différence première</i>		Conclusion
	Avec constante	Avec constante et avec tendance	Avec constante	Avec constante et avec tendance	Break au niveau de la constante	Break au niveau de la constante et tendance	Break au niveau de la constante	Break au niveau de la constante et tendance	
YIELD3M	0.48	-0.39	-7.86	-8.18	-9.99	-5.51	-	-	I(0)
YIELD1YEAR	-0.26	-0.96	-9.17	-9.37	-6.20	-5.98	-	-	I(0)
YIELD2YEARS	-0.56	-1.08	-10.43	-10.60	-5.81	-5.89	-	-	I(0)
YIELD5YEARS	-1.13	-1.09	-19.64	-19.74	-5.05	-5.62	-	-	I(0)
YIELD10YYEARS	-1.39	-0.87	-19.88	-19.98	-4.74	-3.25	-59.18	59.33	I(1)
EESWE2BGNCURNCY	-0.65	-1.30	-9.82	-9.94	-6.06	3.29	-	-	I(0)
EESWE5BGNCURNCY	-1.00	-1.34	-10.62	-10.77	-5.88	-3.21	-	-	I(0)
EESWE10BGNCURNCY	-1.16	-1.07	-60.63	-60.67	-4.86	3.28	-60.64	-60.86	I(1)
GOLD_GROWTH	-66.08	-66.09	-	-	-65.81	-65.92	-	-	I(0)
GOV_GROWTH	-7.18	-7.32	-	-	-7.44	-8.03	-	-	I(0)
VSTOXX	-6.63	-6.67	-	-	-7.47	-8.28	-	-	I(0)
MSFXEURINDEX	-2.11	-2.57	-60.23	-60.23	-2.98	-2.98	-60.26	-60.30	I(1)
EURIBOR3M	-0.42	-0.91	-6.17	-6.44	-7.08	-5.35	-	-	I(0)
EURIBOR12_M	0.08	0.98	-26.31	-26.48	-7.19	-6.25	-	-	I(0)
M2_GROWTH	-6.14	-6.14	-	-	-9.52	-6.95	-	-	I(0)
INFLATION	-1.56	-1.67	-6.09	-6.09	-3.30	-3.94	-6.37	-6.45	I(1)

Test ADF : Les valeurs critiques à un seuil de significativité de 5% : -1.94 pour la spécification sans constante sans tendance, -2.86 avec constante sans tendance et -3.41 avec constante et tendance. Test ZA : Les valeurs critiques à un seuil de significativité de 5% : -1.94 pour la spécification sans constante sans tendance, -4.93 avec constante sans tendance et -5.08 avec constante et tendance

### Annexe n°6 : Résultats du test VIF

	VIF VALUE
Variable dépendante : YIELD 3M	
VSTOXX_GROWTH	1.531828
MSFXEUR_INDEX_GROWTH	1.011962
M2_GROWTH	1.005994
D(INFLATION)	1.540993
D(EURIBOR3M)	1.005878
Variable dépendante : YIELD 1 ANS	
M2_GROWTH	1.530266
D(EURIBOR12M)	1.003404
D(INFLATION)	1.007765
MSFXEUR_INDEX_GROWTH	1.005802
VSTOXX_GROWTH	1.012300
Variable dépendante : YIELD 2 ANS	
D(EESWE2BGN_CURNCY)	1.301177
M2_GROWTH	1.736045
GOV_GRWOTH	1.001172
MSFXEURINDEX_GROWTH	1.001876
D(INFLATION)	1.049848
Variable dépendante : YIELD 5 ANS	
D(EESWE5BGN_CURNCY)	1.003323
GOLD_GROWTH	1.063694
GOV_GROWTH	1.000405
M2_GROWTH	1.511648
MSFXEURINDEX_GROWTH	1.064796
Variable dépendante : YIELD 10 ANS	
MSFXEUR_INDEX_GROWTH	1.064720
M2_GROWTH	1.509493
GOV_GROWTH	1.001274
GOLD_GROWTH	1.065001
D(EESWE10_BGN_CURNCY)	1.002456


**Annexe n°7 : Résultats du test effet ARCH et du test d'autocorrélation des erreurs**

	Test d'autocorrélation des erreurs (Test de Breusch-Godfrey)		Test Effet ARCH	
	Valeur	p-value	Valeur	p-value
YIELD3M	374802.1	0.00	286073.7	0.00
YIELD1YEAR	256401.2	0.00	105588.3	0.00
YIELD2YEARS	121014.3	0.00	1174147.1	0.00
YIELD5YEARS	71639.84	0.00	18445.92	0.00
YIELD10YEARS	64881.59	0.00	19201.05	0.00

## Pricing Of An Index-based Flood Insurance Product Using Satellite Data: Case Of Cereal Production Of The Wilaya of El Tarf -Algeria-

Loubna CHIKHI

Ministère des Finances Algérien



### Abstract

Flooding in Algeria is the most frequent natural catastrophe and ranks second in terms of severity. The agricultural sector, which plays a significant role in Algeria's economy and is a cornerstone of national food security, is particularly vulnerable to the devastating risks posed by floods. Traditional indemnity-based insurance allows farmers to transfer the financial consequences of agricultural flood risk through the payment of a premium, and the insured is indemnified in the event of a claim, following an assessment of loss declarations. However, such insurance faces several constraints that can limit accessibility for farmers.

To address these challenges, this research develops an index-based insurance product to provide coverage to Algerian farmers against flood risk. The indemnity under this index insurance is triggered when a predefined threshold is exceeded, rather than relying on individual loss assessments. This study defines the index and models the probability distribution to accurately price the insurance product.

Due to the absence of historical loss data, we employed a probabilistic model, starting with assessing the vulnerability of agricultural land to flooding. This model leverages a Generalized Linear Model (GLM) framework, incorporating meteorological and geographic data obtained from satellite sources. We constructed a damage function specific to our study area, linking precipitation levels to probable damage. Additionally, extreme value theory was applied to model extreme precipitation events, enabling us to determine the actuarial cost of coverage.

**Keywords :** Index-based flood insurance, Extreme precipitation, Extreme value theory, Satellite data, Generalized Linear Model.

### Résumé

Les inondations, la catastrophe naturelle la plus fréquente en Algérie et la deuxième en termes de gravité, représentent un risque majeur pour le secteur agricole. Ce pilier de l'économie et de la sécurité alimentaire nationale est particulièrement vulnérable, mais les contraintes des assurances traditionnelles – coûts élevés, complexité, et délais d'indemnisation prolongé – réduisent leur efficacité pour protéger les agriculteurs.

Pour répondre à ces défis, cette recherche propose un produit d'assurance indicielle spécialement conçu pour le contexte algérien. Ce type d'assurance déclenche l'indemnisation dès qu'un seuil prédéfini de précipitations est dépassé. Face à l'absence de données historiques sur les sinistres, un modèle probabiliste a été développé, s'appuyant sur des données satellitaires et un Modèle Linéaire Généralisé (GLM). Une fonction de dommage reliant les précipitations aux pertes potentielles a été construite, tandis que la théorie des valeurs extrêmes a permis de modéliser les événements rares et de définir des tarifs précis.

**Mots-clés :** Assurance indicielle, Inondations, Précipitations extrêmes, Données satellitaires, Modèle probabiliste.

### Introduction

Floods are among the most frequent and destructive natural disasters, causing major economic losses and fatalities. According to the Swiss Re Institute, floods have accounted for over a third of natural catastrophe-related fatalities since 2011, with cumulative insured losses exceeding USD 88 billion between 2012 and 2022. This growing impact is closely tied to climate change, which has intensified the frequency and severity of extreme weather events. Rising global temperatures and shifts in precipitation patterns have led to more intense rainfall and, consequently, more severe floods (Amarnath, Taron, Alahacoon, & Ghosh, 2023).

In Algeria, part of the climate-vulnerable Mediterranean basin, floods have become increasingly frequent and intense. This has severe implications for the agricultural sector, which contributes 11.6% to the GDP and employs nearly 23% of the population. Smallholder farmers, who rely heavily on their crops for income and sustenance, are particularly at risk. Despite the sector’s importance, flood risks in Algerian agriculture are considered uninsurable under traditional insurance frameworks due to challenges (Sahnoune, Belhamel, Zelmat, & Kerbach, 2013).

This study addresses the challenge of transferring flood risk in agricultural landscapes through the development of index-based insurance, particularly where historical damage data, crucial for insurance modeling, is absent. This study focuses on insuring cereal production, a key sector for Algeria’s economy and food security. The Wilaya of El Tarf was selected as the study area.

Previous academic researches on flood index insurance by (Idir, 2021) and (Ritling & Nguyen, 2014) have predominantly utilized simple linear equation to establish a relationship between precipitation and resultant damages. However, our study seeks to advance beyond this methodology by developing a method inspired by probabilistic models that integrates both vulnerability and damage functions, specifically tailored to the characteristics of the study area. This research leverages satellite data to construct a vulnerability function that better reflects the impact of extreme precipitation on agricultural land.

The study first establishes a theoretical foundation, discussing natural catastrophes, flood risk, and the insurability of agricultural floods. It contrasts traditional indemnity insurance with index-based insurance.

The empirical analysis focuses on constructing and pricing an index-based flood insurance product for Algeria's agricultural sector. It assesses the regional context, defines a precipitation-based index, models flood vulnerability, and utilizes extreme precipitation data to determine pricing.

## 1. Literature review

### 1.1. Generalities on flood risk

In general, natural catastrophes refer to sudden and violent events of natural origin, often resulting in loss of life, significant material damage, and serious socio-economic consequences. These events, typically unpredictable, can have a devastating impact (Hoeppe, 2016). On the other hand, flood originates from the occurrence of heavy and sustained rainfall over measurable time intervals, typically in hours, half-days or accumulative days (Tabet Helal, Baghli, Bensaoula, Mami, & Ghellai, 2012).

Assessing flood risk relies on various factors, including the period of return (frequency of occurrence), duration of the flood, and the velocity of flooding (speed of floodwater flow).

**Table 1: Flood assessment factors**

<b>Return period</b>	The anticipated (average) interval, typically measured in years, between surpassing a specific extreme threshold, it serves as a measure of how often a flood event is expected to occur. (Messner, Penning-Rowsell, Green, & Meyer, 2007)
<b>Duration</b>	Measured in terms of the number of days submerged. It's noteworthy that even during the most severe floods, the duration is unlikely to surpass three days. (Antolini, Tate, Dalzell, & Young, 2019)
<b>Flow velocity</b>	The flow velocity is conditioned by the slope of the bed and its roughness, which is a characteristic of the surface state of the soil. (Vozinaki, Karatzas, Sibetheros, & Varouchakis, 2015)

Flooding is primarily driven by intense episodes of rainfall, but its impact is significantly influenced by various geographical, topographical, and landform factors that exacerbate an area's vulnerability. In term of vulnerability, Agriculture is particularly vulnerable to flooding, since agricultural lands are often strategically located in proximity to water bodies to ensure reliable access to irrigation. Additionally, these lands are frequently situated in low-lying areas and floodplains because of their fertile soils. These same factors heighten flooding, particularly during periods of heavy rainfall. Among these factors we find :

**Table 2:Flood vulnerability factors**

<b>Elevation</b>	Lower elevations areas are more prone to inundation as water flows from higher to lower terrain. Consequently, floodplains are especially susceptible to flood conditions. (Schwarz & Kuleshov, 2022)
<b>Slope</b>	Areas characterized by gentle slopes, experience frequent flooding because the water discharge is impeded by the lack of gradient. (Megahed, Abdo.M, Abdelrahman.A.E, Scopa, & Hegazy.N, 2023)
<b>Soil types</b>	Soils with lower infiltration increase surface runoff leading to floods. (Basri, Syakur, & Azmeri, 2022)
<b>Soil moisture</b>	As soil moisture content rises, the rate of infiltration decreases, which in turn increases the likelihood of flooding. (Goel & Garg, 2019)
<b>Topographic wetness index (TWI)</b>	A quantitative measure used to predict areas of potential water accumulation based on terrain characteristics.
<b>Distance to rivers</b>	Areas closer to a river are more susceptible to inundation due to the river's capacity to overflow its banks during heavy rainfall events. (Buddha & Binu, 2023)

**1.2. Insurance against flood risk in agriculture : between traditional and index insurance**

Floods stand out as a peril that challenges the fundamental principles of insurability more than any other (Swiss-re, 2012). The unpredictability complicates damage estimation and, coupled with their catastrophic nature, undermines the insurance principle of risk spreading (Kast & Lapied, 2012).

Traditional agricultural insurance faces structural hurdles in addressing flood risks. Adverse selection, where insurance primarily attracts high-risk individuals, is a major concern (Mcmahon, 2019). Additionally, indemnity-based insurance is costly due to expert assessments and information asymmetry, driving up premiums (Leblois & Quirion, 2013). Delays in claim settlements and disputes over loss appraisals further diminish demand, widening the protection gap (Lin & Kwon, 2020).

Index-based weather insurance is a significant institutional advancement that has the potential to transform the availability of formal insurance for many farmers. Index-based insurance operates by utilizing triggers based on weather indicators, rather than relying on direct estimates of losses at the individual farm level. It is characterized by a standardized format, eliminating the need for specialized professionals to verify or validate losses, resulting in relatively cheap administrative expenses (Annibale, Martina, Monteiro, & Galasso, 2021).

For floods, the commonly used index is related to the accumulation of precipitation over several days. In this context, a flood event is defined as the continuous period during which the cumulative precipitation exceeds a certain threshold. When the amount of rainfall surpasses the specified level, the farmers who have joined the program are eligible to receive a payment (Amarnath, Taron, Alahacoon, & Ghosh, 2023).

**2. Empirical Analysis**

**2.1. Study area**

The Wilaya of El Tarf has been chosen for this study due to its high agricultural vulnerability to flooding. The February 2012 flood caused damages estimated at 2.326 billion Algerian dinars, the highest among major floods affecting the agricultural sector. Additionally, satellite imagery documents flood events in the area, offering valuable data for developing the vulnerability function discussed later.

The wilaya of El Tarf is located in the extreme northeast of Algeria. It is bounded to the north by the Mediterranean Sea, to the east by Tunisia (Governorate of Jendouba), to the south by the wilaya of Souk Ahras, to the southwest by the wilaya of Guelma, and to the west by the wilaya of Annaba. The region has a significant hydrological network and numerous bodies of water, including two watersheds and several wetlands composed of five lakes and two dams.

## 2.2. Methodology and data

Lacking historical flood data, we apply a probabilistic model to generate a catalog of catastrophic loss events with associated probabilities and expected losses. It consists of three main components :

- **Hazard Assessment: that** aims to simulate fictitious but realistic events in order to measure the potential impact of more extreme events varying certain parameters, such as precipitation intensity.
- **Vulnerability Analysis: that** aims to determine the average loss ratio based on the intensity of the hazard. The average loss ratio is defined as the total amount of the loss relative to the total value of all insured objects in the considered area.
- **Loss Estimation:** The damage model aims to calculate the amount of losses based on the hazard and vulnerability.

### ❖ Precipitation Data (The hazard)

We have at our disposal daily precipitation data in millimeters for the Wilaya of El Tarf spanning the past 38 years, from 1985 to 2023. These real-time satellite data are collected from NASA's CERES and MERRA-2 datasets, derived from NASA's Global Precipitation Measurement (GPM).

### ❖ Vulnerability Data

Flood vulnerability data were identified through an extensive review of existing literature and discussions with researchers from the ITGC (Technical Institute of Large Crops), the National Institute of Soils, Irrigation, and Drainage (INSID) and the National Agency for Water Resources (ANRH). We leverage data from multiple satellite sources available of internet that are designed specially to conduct comprehensive geological and meteorological analyses.

- The land use map is obtained from the Environmental Systems Research Institute (ESRI), derived from ESA Sentinel-2 imagery at a 10m resolution.
- Digital Elevation Model (DEM) images are sourced from the ASTER Global Digital Elevation Model, providing a 30m resolution. This data, available on NASA's Earth Data Search, has been used to extract slope, elevation, and TWI maps.
- The digital soil map is obtained from the Food and Agriculture Organization (FAO)
- The soil moisture data is sourced from NASA's MERRA-2 Reanalysis.

### ❖ Exposure data

Data on agricultural land and cereal production is collected from the Ministry of Agriculture. This data will be applied to the damage rate of our study area to accurately assess the value of the damage.

## 2.3. The construction of the Index

The construction of the index is the most critical step in the implementation of index-based insurance. As noted in the literature review, continuous rainfall measurements are a reliable proxy for



assessing flood events in index-based insurance. Based on event analysis and ANRH expert input confirming that extreme precipitation in Algeria rarely exceeds two days, we conclude that two-day cumulative precipitation better represents flood occurrences. The 100 mm threshold detects 5 of the 6 major flood events in the study area. Thus, a 100 mm two-day cumulative precipitation, with a two-year return period, is recommended as the insurance trigger index.

To build the index the steps are as follows :

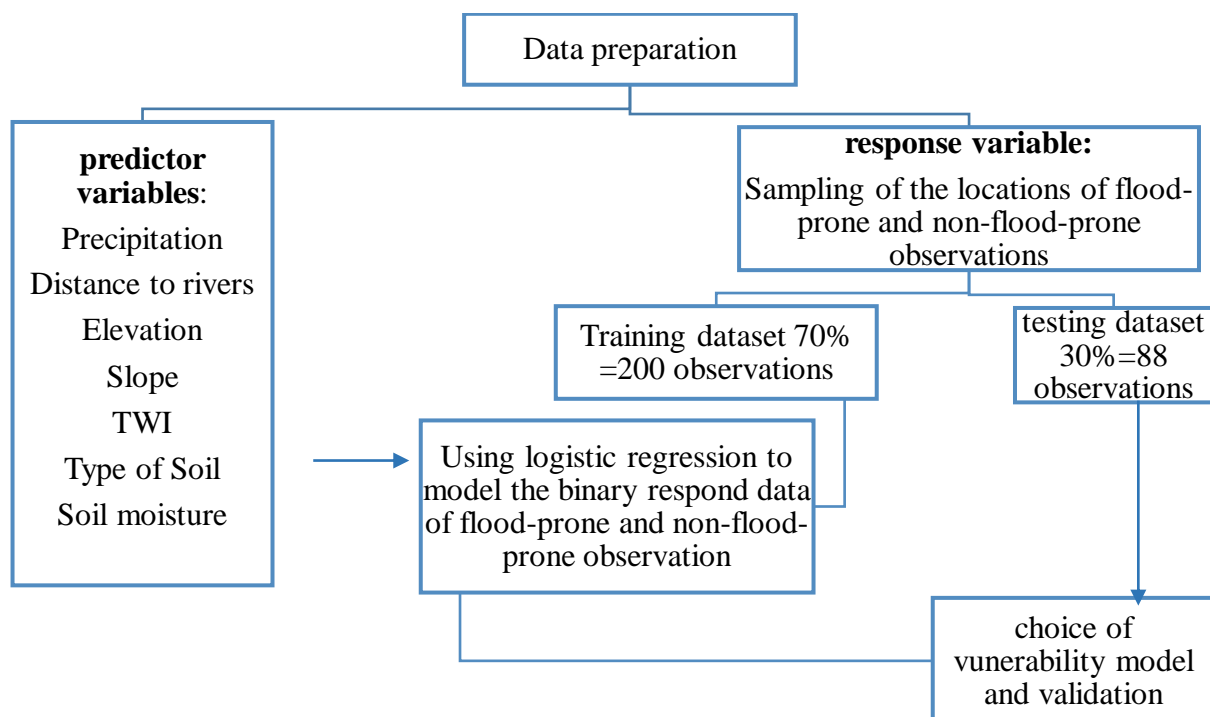
- Two-day cumulative rainfall is calculated daily from September to July, aligning with the index insurance coverage period.
- An event is triggered when the cumulative precipitation over two days exceeds 100 mm and ends when it falls below this threshold. For each detected event, only the peak of the cumulative two-day rainfall is used to calculate the loss rate.
- Linking the rainfall to a loss rate, commonly referred to as the vulnerability rate. The modeling of vulnerability rates will be addressed in detail in our next section.
- Construct a damage curve, indicating the damage caused by floods for each level of precipitation in the area.
- Apply the damage rate to our exposure, which is the cereal production in the Wilaya under study.

## 2.4. Modeling and results

### 2.4.1. Modeling flood vulnerability

We construct a GLM model to explain flood vulnerability. A total of 288 flood-prone and non-flood-prone observations are selected and randomly split into two datasets in a 70/30 ratio of training and testing datasets. Since the risk of flood is treated as a binary classification task in GLM models, flood observations are assigned a value of 1, while non- flood- prone observations are given a value of 0. Finally, the values of the flood influence factors extracted from these observations and organized into a file, which is processed using R software.

Figure 01: Methodological Flowchart for Flood Vulnerability



After addressing multicollinearity in the model and applying a stepwise approach to include and exclude variables, The selected model is the one that has the highest McFadden's R-squared and the lowest AIC.

```
Call:
glm(formula = RD ~ precipitation + twi + distance + moisture,
     family = binomial(), data = detection_data)
```

```
Deviance Residuals:
    Min       1Q   Median       3Q      Max
-2.36707 -0.19361 -0.01985  0.02968  2.61506
```

```
Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept) -2.317e+01  5.244e+00 -4.419  9.91e-06 ***
precipitation  3.771e-02  1.227e-02  3.074  0.00211 **
twi           1.167e+00  2.424e-01  4.815  1.47e-06 ***
distance     -9.593e-04  3.165e-04 -3.030  0.00244 **
moisture      3.888e+01  8.308e+00  4.680  2.87e-06 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 277.179  on 199  degrees of freedom
Residual deviance:  64.848  on 195  degrees of freedom
AIC: 74.848
```

```
Observations    200
McFadden's R^2  0.808
```

The Hosmer-Lemeshow (HL) test, a widely used goodness-of-fit measure, has been applied to evaluate the logistic regression model.

**Table 3: Hosmer–Lemeshow test results**

X-squared	Degrees of Freedom (df)	P-value:
<b>2.1078</b>	8	0.9775

*Source: Established by the author using R software*

**P-value=0.9775 > 0.05:** We fail to reject the null hypothesis. There is no significant difference between the observed and expected frequencies.

A confusion matrix is used to evaluate the model performance. Our testing dataset contains 88 observations, the matrix of confusion for our model is presented in the table :

**Table 4:Confusion matrix for the logistic regression**

	false	true
false	44	3
true	4	37

*Source: Established by the author*

**Table 5: Evaluation of the GLM model**


<b>Accuracy</b>	$\frac{TP+TN}{TP+TN+FP+FN}=92.045\%$	The proportion of correct predictions
<b>Precision</b>	$\frac{TP}{TP+FP}=92.5\%$	The proportion of positive predictions that are actually correct
<b>Recall</b>	$\frac{TP}{TP+FN} = 90.24\%$	The proportion of actual positives that are correctly identified by the model.
<b>Specificity</b>	$\frac{TN}{TN+FN} = 93.62\%$	Specificity measures the proportion of actual negative cases that the model correctly identified.

These metrics suggest the model is well-calibrated and capable of effectively distinguishing between flooding and non-flooding cases, making it a reliable tool for predicting such events.

**2.4.2. Determination of the destruction rate function**

To estimate the damage function for our study area, we assume that cereal production is uniform across the entire crop area. We then randomly select 20,000 locations within this area. By taking the average damage rate from these randomly chosen locations, we can represent the average damage rate for the entire study area.

**Figure 2: Destruction function of the wilaya of El Tarf**



The only concrete evidence we have is from reports by the FGCA, which indicates that the damage rate for cereal crops during the flood event on February 22-23, 2012, was 34.34%. Our model estimates the damage rate for the same event at 35.12%, demonstrating a detection accuracy of 97.77%. While this single data point cannot fully confirm or refute the model's accuracy, it is valuable. Throughout this research, we aim to leverage all available information, given the lack of historical damage data.

**2.4.3. Modeling the hazard**

Understanding the behavior of extreme precipitation events is crucial for effective hazard assessment and insurance modeling, we will explore the application of EVT in modeling the exceedances of a two-day cumulative precipitation threshold, in order to determine the pure premiums.

❖ **Addressing independency and stationarity**

Ensuring the independence of data series is a challenge in applying extreme value theory. To work with EVT, it is common to assume that extremes are independent when they exceed a sufficiently high threshold  $u$ . This can be achieved through the decluttering technique which is the most commonly used approach. To confirm the result of the decluttering we use The Wald-Wolfowitz Runs Test which is a non-parametric test for independent samples.

**Table 6:Wald-Wolfowitz Runs Test**

Statistic	P-value	Hypothesis
<b>1.1548</b>	0.2482	We fail to reject the null hypothesis. There are no significant patterns or clustering in the Data.

Extreme value analysis traditionally relies on the assumption of stationarity, which implies that statistical properties of the data remain constant over time.

To inspect the stationarity, first we use Kwiatkowski–Phillips–Schmidt–Shin (KPSS) for deterministic trend and The Phillips-Perron (PP) Unit Root Test which is a statistical test used to determine whether a time series has a stochastic trend.

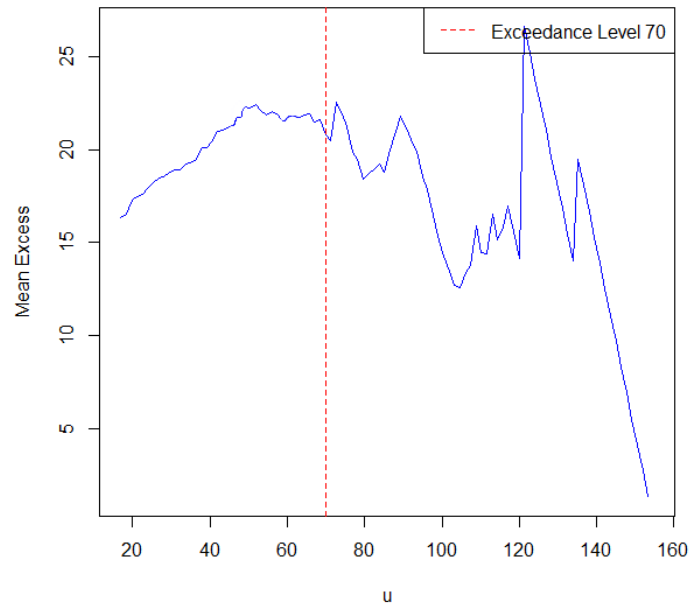
**Table 7:Testing stationarity**

Test	Level Statistic	Truncation Lag Parameter	p-value:	Hypothesis
KPSS	0.043138	3	>0.1	There is no significant evidence against the null hypothesis of trend stationary.
Dickey-Fuller Z(alpha):	-61.26	3	0.01	The time series does not have a unit root.

❖ **Threshold determination**

We need to determine a threshold to model our distribution. The selection of this threshold is among the analytical complexities of the EVT modeling. This threshold must be sufficiently high to ensure that the approximation by the distribution is valid and to guarantee the economic reliability of the model. We use the mean excess plot to determine the threshold graphically.

**Figure 3: Mean Excess Function**



The threshold selection is made from the point where the curve  $e(u)$  appears to have a linear behavior. According to the figure, the curve is almost linear when the threshold  $u$  is around 70 mm.

❖ **Index modeling**

An index is defined as the exceedance of the threshold for aggregated rainfall over 2 days. Therefore, our primary approach will be to model these threshold exceedances using the POT method, which employs the Generalized Pareto Distribution (GPD). We will be studying the distribution of  $(X|X > 70 \text{ mm})$  which is the threshold used for modeling and then derive  $(X|X > 100 \text{ mm})$  that will be used for pricing. Below is a summary table of the estimated parameters.

**Table 8: Results of GPD estimation**

Threshold	Scale parameter $\beta$	Shape parameter $\xi$
<b>70</b>	<b>29.3632080</b>	<b>-0.2701485</b>

The GPD model, with a shape parameter of -0.2701, suggests a finite upper bound, meaning the probability of exceeding a maximum value is zero. This bound estimates the maximum two-day rainfall at 178.69 mm. However, historical events, show higher values, challenging the GPD estimate. Given these extremes, capping rainfall at 178.69 mm may underestimate risks, highlighting the need to consider the Generalized Extreme Value (GEV) distribution for better risk assessment.

The results of the modeling are as follows :

**Table 9: Results of GEV estimation**

	Location	scale	shape
Estimate	83.5282	12.6840	<b>0.1781</b>
Standard errors	<b>2.2687</b>	<b>1.8612</b>	<b>0.1881</b>

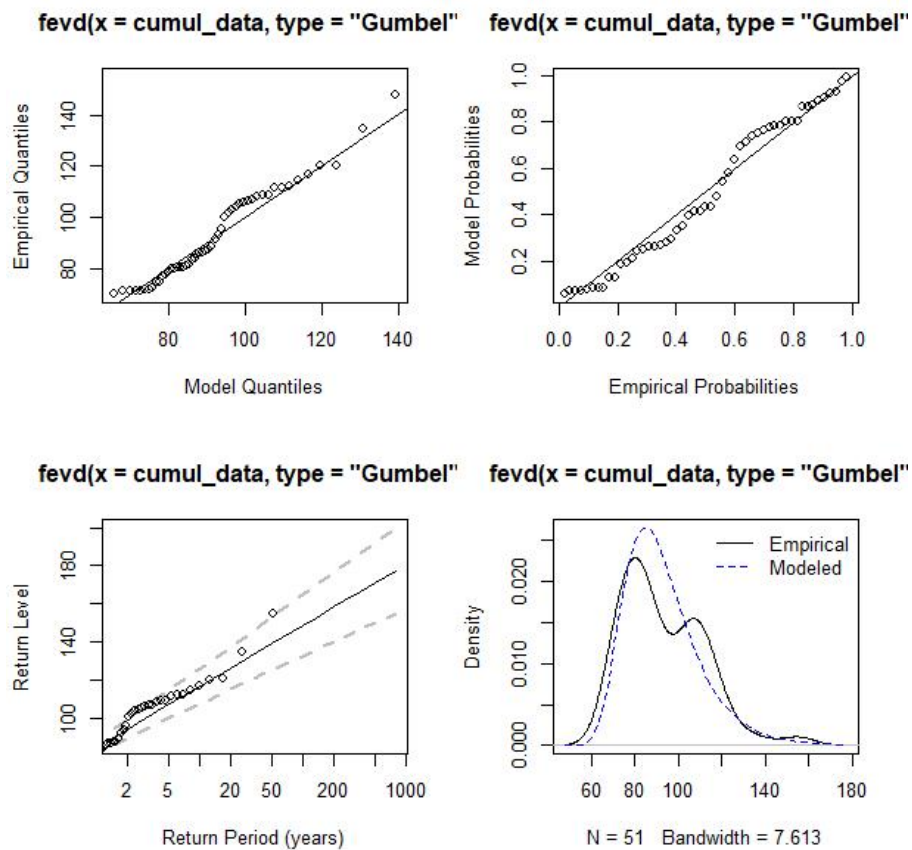
We need to test whether the shape parameter  $\xi$  is significantly different from zero. We compute the student's t-statistic for  $\xi$  as follows :

$$T - Statistic = \frac{SE(\hat{\xi})}{\hat{\xi}} = \frac{0.1781}{0.1881} = 0.9468$$

P-value= 0.34846

For a student's t-test at the 5% significance level, we fail to reject the null hypothesis that  $\xi$  equals zero. This result implies that the underlying Generalized Extreme Value (GEV) distribution can be identified as a Gumbel distribution.

**Figure 4: Goodness of Fit of the Data to the Gumbel Distribution**



To further confirm the goodness of fit of the Gumbel distribution to the two-day cumulative precipitation data, we employed the statistical test of the Anderson-Darling.

According to (Abidin. N.Z, 2012), it is considered as the most powerful Goodness Of Fit test for Gumbel distribution.

**Table 10: Anderson-Darling goodness of fit statistic test**

Test Statistic:	P-value	Hypothesis
-----------------	---------	------------

0.965	0.376	The sample data follows Gumbel distribution.
-------	-------	--

We do not reject the null hypothesis ; therefore, the Gumbel distribution is a reasonable fit for the two-day cumulative precipitation data according to the Anderson-Darling test.

**2.4.4.Pure premium calculation for the Wilaya of El Tarf**

Mathematically, the pure premium is defined as the expected value of the indemnities that will be paid out : Pure Premium=E[S].

To facilitate the calculation of the pure premium, we assume that the occurrence of events is independent of the associated payments (Vi , N ⊥ Xi). Furthermore, we posit that the payments for each event are independent and identically distributed (i.i.d.). Under these conditions, the pure premium can be expressed as :

$$\text{Pure Premium} = E(N) \times E[f(X | X > 100)]$$

To stabilize the pricing model and achieve accurate estimates of E(X), we will utilize the Law of Large Numbers through a Monte Carlo simulation. The distribution of (X|X>100) will be estimated using the parameters of the already modeled Gumbel distribution, with the modeling threshold selected at u=70. To obtain a stable model, we will simulate the variable (X|X>100) 100,000 times. The conditional CDF of X given X>100 is :

$$F_{X|X>100}(x) = \frac{S(x)}{S(100)} = \frac{1 - \exp(-\exp(-\frac{x - \mu}{\beta}))}{1 - \exp(-\exp(-\frac{100 - \mu}{\beta}))}$$

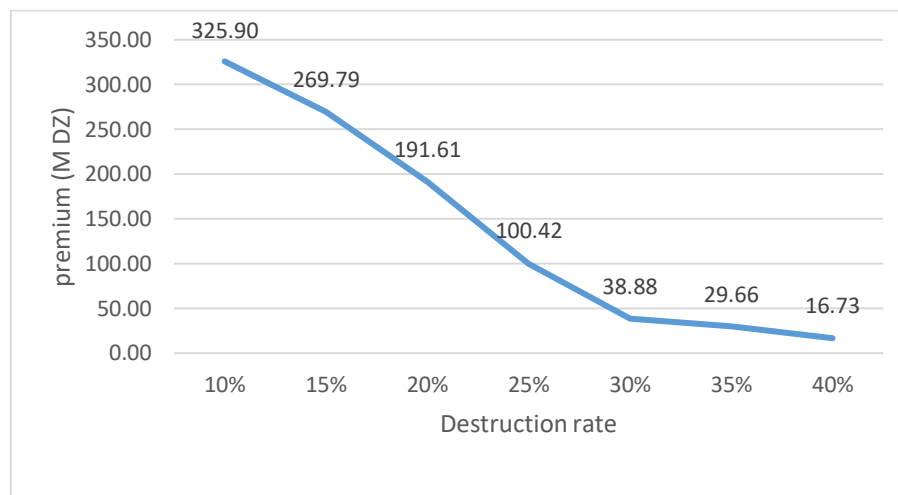
We have defined the attachment point of the index at a damage rate of 20% which is the damages expected with a 100mm precipitation. The coverage limit is set at the total cereal production for the Wilaya of El Tarf, according to the most recent figures from the Ministry of Agriculture available.

The table below summarizes the modeling results :

**Table 11: The pure premium for a 20% destruction rate**

Destruction rate	Coverage (M DZD)	Premium (M DZD)	Premium rate	Premium per Ha (DZD/Ha)	
20%	3 061.083	191.605	6.26%	Durum wheat	10 003.1499
				Soft wheat	10 640.9943
				Barley	3 670.35898

We can offer other coverage options for farmers by adjusting the attachment to align with the risk profile in the area. Increasing the attachment lowers the rate, and vice versa, lowering it increases the pure premium.

**Figure 05: Sensitivity of the pure premium to the choice of the attachment point**

### 3. Discussion

To ensure the entire winter cereal production in the Wilaya of El Tarf, the required annual premium for coverage spanning from September to July is 191.605 million Algerian dinars, corresponding to a premium rate of 6.26% for a 20% destruction rate. If the coverage is extended to include a 10% destruction rate, the annual premium increases to 325.903 million Algerian dinars, with a premium rate of 10.65%. This premium level may be prohibitive for smallholder farmers. As highlighted in the first chapter, index insurance is recognized as a potentially effective mechanism for providing affordable protection against catastrophic, correlated risks, particularly for low-income households in developing countries.

Adopting an index-based insurance approach allows for a reduction in the adjustment costs embedded in the premium, which, based on reports from the MADR, account for 3% of the total damages. Moreover, the financial strain on farmers could be alleviated by implementing effective financing mechanisms.

Government intervention, particularly through the provision of premium subsidies for the index-based flood insurance, serves to mitigate the financial burden on insured farmers and provides the government with the strategic advantage of predetermining budget allocations for agricultural disaster relief.

Moreover, the establishment of an index insurance in Algeria may require partnerships with various public authorities and institutions, such as the ONM, the ANRH, and ASAL. The data necessary for constructing an index can be costly to obtain from the public authorities that own it. Additionally, the creation of public-private partnerships (PPP) with statistical institutes and meteorological stations can partially address the issue of the cost and improve the precision of the index which allows the reduction of the basic risk.



## Conclusion

Algeria's climate is characterized by significant variability, particularly in its Mediterranean regions, where extreme precipitation events contribute to about 20% of annual rainfall. With climate change, the country faces increasing vulnerability to extreme weather, particularly impacting agriculture, a crucial sector for both the economy and food security.

Currently, agricultural flood risks are considered uninsurable under Algeria's existing system, managed by the FGCA, which offers limited coverage and faces challenges such as high administrative costs, and slow indemnity processes. Traditional insurance struggles to meet farmers' needs, particularly smallholders, who are disproportionately affected by floods.

Index-based insurance presents a promising alternative by offering faster payouts and lower administrative expenses. This model relies on predefined precipitation thresholds recorded via meteorological stations or satellite data. In this study, a threshold of 100 mm over two days was used to determine payouts for flood-related cereal crop damage in El Tarf. A probabilistic model was applied to simulate potential losses, incorporating extreme precipitation data and satellite imagery to assess regional vulnerability.

However, several limitations must be addressed. The lack of historical flood damage data required reliance on probabilistic modeling, which may not fully capture real-world complexities. Additionally, the accuracy of satellite data can be affected by discrepancies with on-the-ground conditions. While the statistical models provide valuable insights, data constraints limit their ability to establish a strong correlation between simulated and actual losses.

To enhance the effectiveness of index-based flood insurance in Algeria, two key areas need improvements :

- Data Collection and Integration : Establishing a comprehensive database on agricultural flood risks, damage statistics, and meteorological data is essential for accurate risk assessment and premium calculations.
- Public-Private Partnerships : Strengthening collaborations between government agencies, private insurers, and international organizations can help create sustainable and accessible insurance solutions while minimizing basis risk.

This research establishes a foundation for index-based agricultural flood insurance, but further refinements are needed. By improving data accuracy and fostering institutional collaboration, index-based insurance can become a viable tool for mitigating agricultural flood risks, ultimately contributing to greater climate resilience in Algeria.

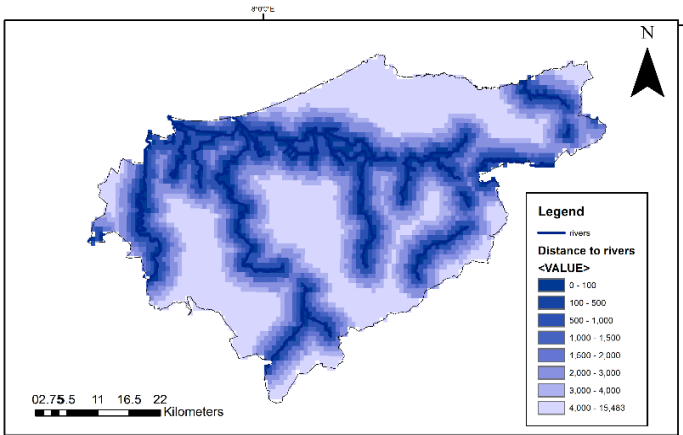
### Références Bibliographiques

- Abidin. N.Z, M. ., (2012). The Goodness-Of-Fit Test For Gumbel Distrubution: A Comparative Study. *Matematika*, 18, 35-48.
- Amarnath, G., Taron, A., Alahacoon, N., & Ghosh, S. (2023, December 1). Bundled Climate-smart Agricultural Solutions for Smallholder Farmers in Sri Lanka. *Frontiers in Sustainable Food Systems*, 7. doi:<https://doi.org/10.3389/fsufs.2023.1145147>
- Annibale, V., Martina, M., Monteiro, R., & Galasso, C. (2021). Precipitation–based Extreme Event Detection for Flood Index Insurance. *International Journal of Disaster Risk Reduction*, 55, 102-108. doi:10.1016/j.ijdr.2021.102108
- Basri, h., Syakur, H., & Azmeri, A. (2022). Floods And Their Problems: Land Uses And Soil. In I. Publishing (Ed.), *IOP Conference Series: Earth and Invironmental Science*, 951. doi:doi:10.1088/1755-1315/951/1/012111
- Coles, S. (2001). Extremes of Dependent Sequences. In *An Introduction to Statistical Modeling of Extreme Values* (pp. 92-104). London: Springer.
- Goel, s., & Garg, A. (2019). Infiltration—A Critical Review. *Sustainable Engineering. Lecture Notes in Civil Engineering*, (pp. 111–120). Singapore: Springer. doi: [https://doi.org/10.1007/978-981-13-6717-5\\_11](https://doi.org/10.1007/978-981-13-6717-5_11)
- Hoepe, P. (2016). Trends In Weather Related Disasters – Consequences For Insurers And Society. *Weather and Climate Extremes*, 11, 70-79. doi:10.1016/j.wace.2015.10.002
- Idir, S. (2021, Juin). Etude d'un produit d'assurance paramétrique contre le risque d'inondation au Maroc. PFE N° 19. INSTITUT NATIONAL DE STATISTIQUE ET D'ECONOMIE APPLIQUEE, Maroc.
- Kast, R., & Lapied, A. (2012). *Economics and Finance of Risk and of the Future*. (1, Ed.) John Wiley & Sons Ltd. doi:DOI:10.1002/9781119205951
- Leblois, A., & Quirion, P. (2013). Les assurances agricoles basées sur des indices météorologiques : bilan des connaissances et agenda de recherche. Paris: Peter Lang. Récupéré sur <https://enpc.hal.science/hal-00801267>
- Lin , X., & Kwon, W. (2020). Application of Parametric Insurance in Principle-compliant and Innovative Ways. *Risk Management and Insurance Review*, 23(2), 121-150. doi:10.1111/rmir.12146
- Mcmahon, L. (2019, 1 7). Modeling Flood Risks: Opportunities and Challenges. Retrieved 8 14, 2024, from actuarial review: <https://ar.casact.org/modeling-flood-risks-opportunities-and-challenges/>

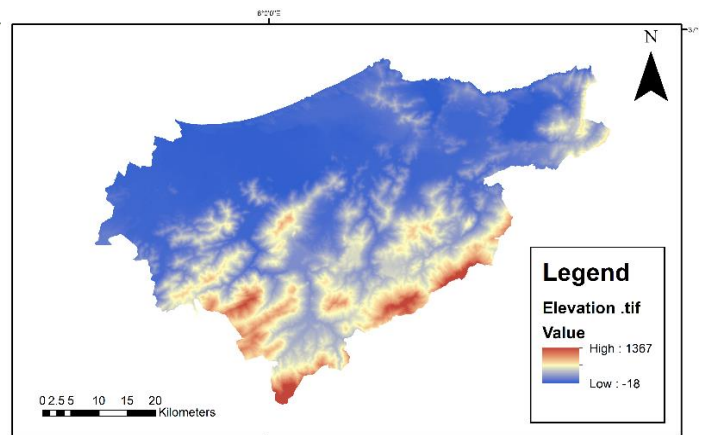
- Megahed, H., Abdo.M, A., Abdelrahman.A.E, M., Scopa, A., & Hegazy.N, M. (2023). Frequency Ratio Model as Tools for Flood Susceptibility Mapping in Urbanized Areas: A Case Study from Egypt. *Appl. Sci*, 13( 9445). doi: <https://doi.org/10.3390/app13169445>
- Ritling, F., & Nguyen, C. (2014, jun). Etude d'un produit d'assurance paramétrique contre le risque de pluie torrentielle en Jamaïque. *Mémoire d'actuariat*. 'ENSAE Paristech, filière Actuariat, France.
- Schwarz, I., & Kuleshov, Y. (2022, 4). Flood Vulnerability Assessment and Mapping: A Case Study for Australia's Hawkesbury-Nepean Catchment. (J. Choi, Ed.) *Remote Sens*, 14(4894). doi:<https://doi.org/10.3390/>
- Swiss-re. (2012). Flood In Switzerland: An Underestimated Risk. Switzerland: Swiss Reinsurance Company Ltd. (Swiss. Retrieved from [https://www.planat.ch/fileadmin/PLANAT/planat\\_pdf/alle\\_2012/2011-2015/Swiss\\_Re\\_\\_Hg\\_\\_2012\\_-\\_Floods\\_in\\_Switzerland.pdf](https://www.planat.ch/fileadmin/PLANAT/planat_pdf/alle_2012/2011-2015/Swiss_Re__Hg__2012_-_Floods_in_Switzerland.pdf)
- Tabet Helal, M., Baghli, A., Bensaoula, F., Mami, E.-F., & Ghellaï, N. (2012). La crue centenaire de Bab EL Oued, Alger (Algérie). *Journées de l'hydraulique*, 34, 1-8. Récupéré sur [https://www.persee.fr/doc/jhydr\\_0000-0001\\_2012\\_act\\_34\\_1\\_1266](https://www.persee.fr/doc/jhydr_0000-0001_2012_act_34_1_1266)

Appendices

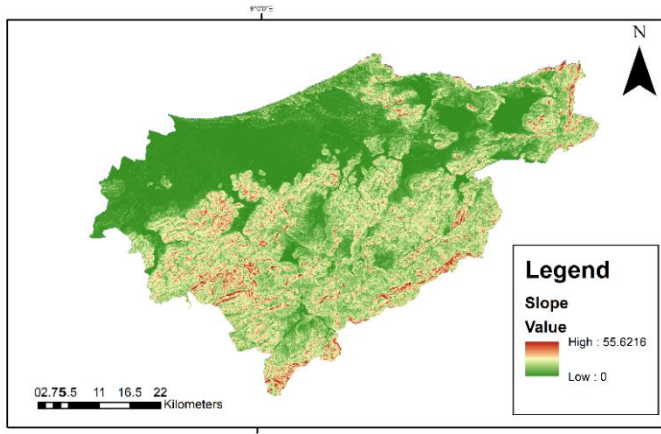
Appendix 01: Distance to Rivers' map of the Wilaya of El Tarf



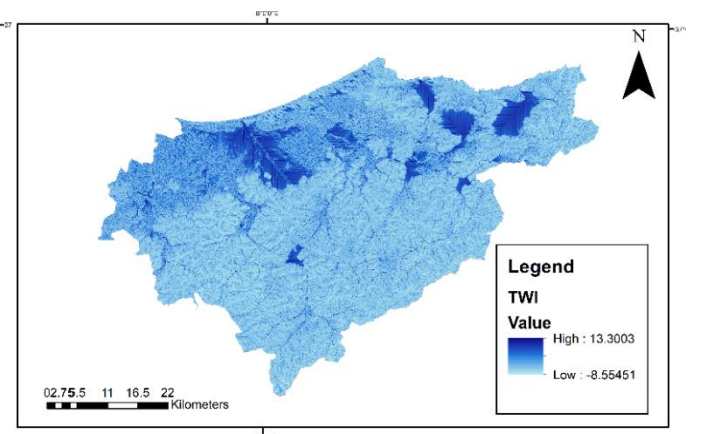
Appendix 02: Elevation's map of the Wilaya of El Tarf



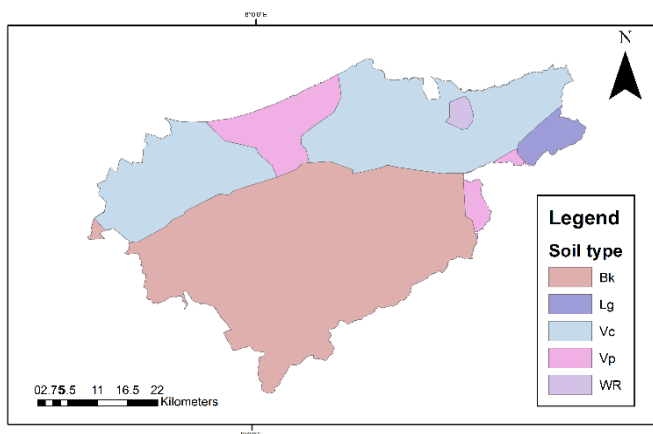
Appendix 03: Slope's map of the Wilaya of El Tarf



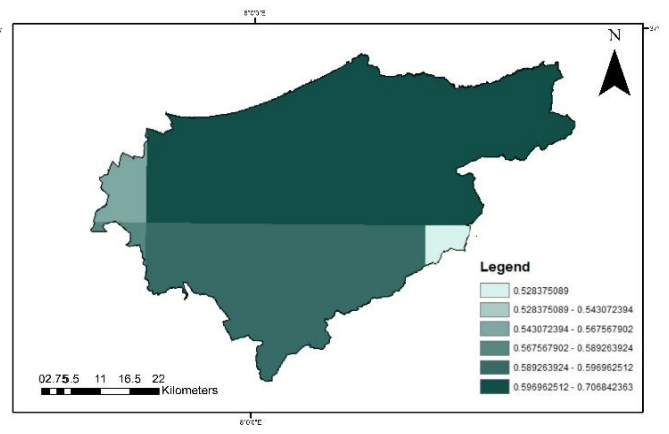
Appendix 04: TWI's map of the Wilaya of El Tarf



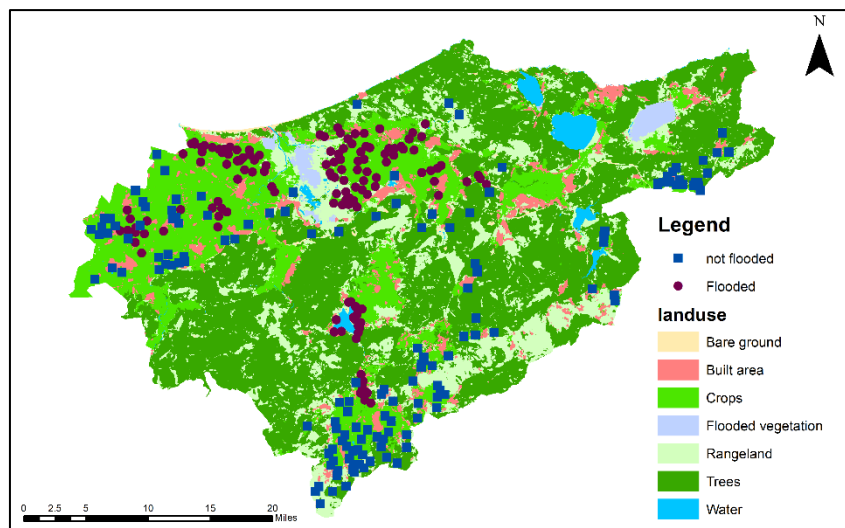
Appendix 05: Soil Types' map of the Wilaya of El Tarf



Appendix 06: Soil Moisture's map of the Wilaya of El Tarf



Appendix 07: Map showing flooded and non-flooded locations in agriculture areas



Appendix 08: Full GLM Model

```
Call:
glm(formula = RD ~ soil+ precipitation + twi + distance + moisture + elevation + slope , family = binomial(), data = detection_data)
```

Deviance Residuals:				
Min	1Q	Median	3Q	Max
-1.65409	-0.20758	-0.00637	0.05641	2.73009

```

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) -9.2349102  5.7627806  -1.603 0.109043
soil         -0.6802383  0.9064224  -0.750 0.452975
precipitation 0.0061285  0.0025418   2.411 0.015889 *
moisture     24.9213302 11.4877797   2.169 0.030054 *
distance     -0.0006934  0.0003516  -1.972 0.048590 *
twi          1.2838917  0.3814987   3.365 0.000764 ***
elevation    -0.0104107  0.0343587  -0.303 0.761596
slope        0.1139497  0.1484255   0.768 0.442651

Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)
Null deviance: 277.179  on 199  degrees of freedom
Residual deviance: 64.768  on 192  degrees of freedom
AIC: 80.768
Number of Fisher Scoring iterations: 8

```

```

> mcfadden_r2 <- (model)["McFadden"]
fitting null model for McFadden-r2
McFadden's R-squared: 0.766333

```

Appendix 09: Spearman Rank Correlation Matrix


	Precipitation	Distance-rivers	TWI	Soil-moisture	Soil-type	Elevation	Slope
Precipitation	1.0000	-0.0804	0.3896	0.3180	0.4050	<b>-0.6426</b>	-0.4565
Distance-rivers	-0.0804	1.0000	-0.3679	-0.1661	-0.2833	0.3249	0.3666
TWI	0.3896	-0.3679	1.0000	0.4644	0.4769	-0.4883	<b>-0.8763</b>
Soil-moisture	0.3180	-0.1661	0.4644	1.0000	<b>0.7024</b>	-0.5193	-0.4514
Soil-type	0.40504	-0.2833	0.4769	<b>0.7024</b>	1.0000	<b>-0.6760</b>	<b>-0.6012</b>
Elevation	<b>-0.6426</b>	0.3249	-0.4883	-0.5193	<b>-0.6760</b>	1.0000	<b>0.7384</b>
Slope	-0.4565	0.3666	<b>0.8763</b>	-0.4514	<b>-0.6012</b>	<b>0.7384</b>	1.0000

Appendix 10: Variance Inflation Factors

moisture	TWI	distance	precipitation	slope	elevation	soil
2.226642	2.332311	1.421402	4.147528	2.621955	2.508062	2.1759

moisture	TWI	distance	precipitation
2.089712	1.121755	1.183385	1.115594

Appendix 11: Illustration of dependency in two days cumulative precipitation.



## L'impact de l'obligation du provisionnement des sinistres tardifs de l'assurance Automobile sur les compagnies d'assurances Algériennes « Cas de la SAA »

Sara HEDDI

Ministère des Finances Algérien



### Résumé

L'inversion du cycle de production crée un besoin important pour les assureurs et les réassureurs en matière de constitution de provisions techniques, nécessitant que les comptes de l'assureur reflètent à la fois les règlements passés et les règlements futurs des sinistres jusqu'à la date de clôture. Il est donc nécessaire de considérer à la fois les sinistres connus et les sinistres tardifs.

Malgré d'énormes efforts de la part du régulateur, nous manquons de solutions efficaces pour rendre obligatoire la constitution de la provision IBNR. De l'autre côté, les réformes en cours du nouveau projet de loi sur les assurances en Algérie offrent l'opportunité d'intégrer cette notion. De plus, cette situation critique a été abordée dans une étude réalisée en 2023 par le Bureau Spécialisé de Tarification en Assurances en Algérie portant sur la provision pour sinistres tardifs.

L'objectif de cet article est d'estimer la provision IBNR de l'assurance Automobile à l'aide des méthodes actuarielles, ainsi que d'estimer l'impact de ce provisionnement sur les principaux éléments du compte de résultat de la compagnie d'assurance, en l'occurrence la SAA, qui constitue notre cas d'étude.

L'estimation des provisions IBNR pour un portefeuille de l'assurance Automobile de la SAA sur la période de 2013 à 2022 (10 ans) réalisée à l'aide des méthodes actuarielles telles que Chain Ladder, Mack et Bootstrap a abouti à un montant de 3 350 Millions DA.

Les principales conclusions soulignent que, d'une part, l'absence de la provision IBNR conduit à une sous-estimation des engagements financiers futurs, et d'autre part, la présence de cette provision constitue un élément significatif du bilan des sociétés d'assurance, avec un impact plus ou moins significatif sur les principaux éléments comptables, surtout lorsque la majorité des risques souscrits impliquent des engagements à long terme, entraînant une augmentation des passifs, ainsi qu'une diminution de 20 Millions DA (soit 0,7%) du résultat net et de la marge d'assurance nette pour l'exercice 2022.

Pour cela, l'instauration de l'obligation de la provision IBNR en Algérie permettrait de garantir une couverture plus complète des engagements futurs des compagnies d'assurances Algériennes, en prenant en compte les sinistres non encore déclarés. Cela consoliderait la stabilité financière du secteur des assurances en Algérie en diminuant les risques de sous-estimation des passifs et en offrant une meilleure protection aux assurés.

**Mots clés** : Inversion du cycle de production, Provisions techniques, Sinistres survenus non encore déclarés (IBNR), Engagements futurs, Sous-estimation des passifs, Chain Ladder, Mack, Bootstrap.

### Introduction

Les autorités de contrôle, telles que le Ministère des Finances en Algérie et le Comité Général des Assurances en Tunisie, veillent au respect de la réglementation en vigueur par les compagnies d'assurance et de la capacité de ces compagnies à honorer leurs engagements envers les assurés.

En assurance Non Vie, la provision pour sinistres à payer (PSAP) demeure la plus significative parmi toutes les provisions techniques Non Vie. Elle représente une estimation des dépenses prévues, tant en capital qu'en frais, indispensables au règlement de tous les sinistres survenus mais non encore réglés, y compris les sinistres survenus non encore déclarés, incluant ceux liés à la garantie de la Responsabilité Civile.

Les IBNR posent un défi majeur pour les assureurs, représentant des pertes non encore rapportées. Ces pertes peuvent provenir de diverses causes, notamment des retards dans la déclaration des sinistres après la clôture de l'exercice.

En Algérie, l'assurance Automobile occupe une position prépondérante, étant le segment le plus important dont la principale couverture pour laquelle l'assureur assume un engagement illimité est la Responsabilité Civile Automobile. Effectivement, la Responsabilité Civile représente une part significative, avec une attention particulière portée à la charge relative à la Responsabilité Civile Corporelle qui se caractérise par son développement long. Cette garantie principale en assurance Automobile est soumise à des retards dans la déclaration des sinistres, et sa gestion peut entraîner des coûts élevés pour les compagnies d'assurance, et affecter leur solvabilité et leur rentabilité.

L'Algérie n'a pas fait l'exception, car la réglementation Algérienne en matière d'assurances n'impose pas aux assureurs la constitution de provisions pour sinistres inconnus (IBNR). Pour remédier à ces problèmes, des études réalisées par le Bureau Spécialisé de Tarification en Assurances sur la provision pour IBNR en 2023 qui ont favorisé l'intégration de la provision IBNR qui nous permet d'éviter une sous-estimation des engagements futurs.

Cette recherche vise non seulement l'estimation de la provision pour IBNR à l'aide des méthodes basées sur l'historique à savoir, Chain Ladder et ses variantes à partir des triangles en fonction d'un ensemble de données comprenant la charge des sinistres, les paiements effectués, le nombre de sinistres et les provisions Dossier/Dossier, etc... de la SAA sur une période de 10 ans allant de 2013 à 2022, mais également l'estimation des impacts de ce provisionnement sur les principaux indicateurs de la compagnie d'assurance.

Le présent article est structuré comme suit : la première partie abordera les concepts clés, ainsi que le régime du provisionnement IBNR et les méthodes d'estimation associées. La deuxième partie sera consacrée au cadre méthodologique approprié pour le cas empirique, l'estimation de l'impact de l'intégration de la provision IBNR et la synthèse des résultats obtenus.

## 1. Revue de la Littérature

### 1.1. La décomposition de la charge ultime

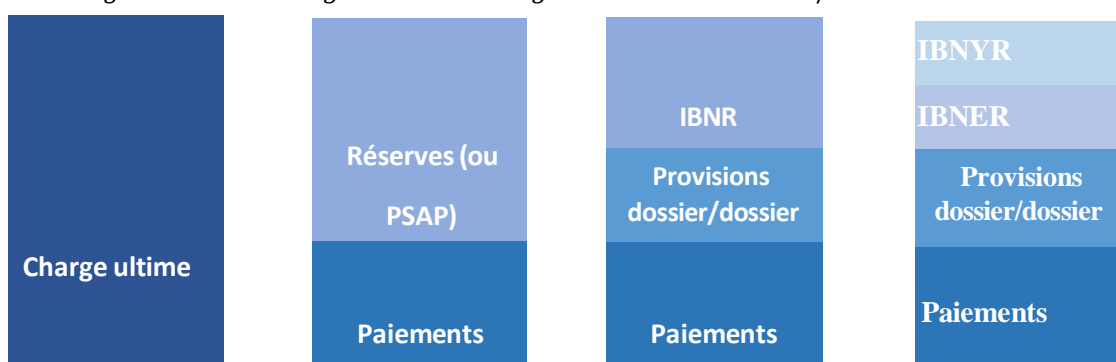
La provision IBNR est significative pour le bilan des compagnies d'assurance, surtout lorsque les risques souscrits ont un développement long. Un niveau adéquat d'IBNR est essentiel pour garantir que l'assureur puisse honorer ses engagements techniques, répondant ainsi aux exigences légales et comptables de manière prudente.

Suivant le contexte de la constitution de provisions, il est crucial de développer une compréhension approfondie de la décomposition de la charge ultime d'un sinistre.

La charge ultime constitue la vision ultime (Coût total final) des sinistres. Cette charge se subdivise comme suit :

**Figure 1 : La décomposition de la charge ultime**

$$\text{Charge Ultime} = \text{Charge} + \text{IBNR} = \text{Règlements} + \text{Provision D/D} + \text{IBNER} + \text{IBNYR}$$



Source : Elaboré par nos soins.



Le coût total d'un sinistre se décompose en plusieurs éléments notamment :

- Les règlements déjà effectués aux assurés ;
- Les provisions pour sinistres connus qui sont les sommes mises à part pour couvrir les sinistres déclarés mais non encore réglés en totalité ;
- Les IBNR correspondent aux provisions pour sinistres inconnus. Ils prennent en compte :
- IBNYR : Provision pour sinistres strictement déclarés avec un retard. Elle est évaluée par segment à chaque date d'inventaire, se manifestant après une période de "x" années sans déclencher de dommages apparents, mais donnant lieu à des demandes d'indemnisation ultérieures ;
- IBNER : Provision destinée à compenser une éventuelle insuffisance dans la provision initiale fixée par le gestionnaire des sinistres. Comme les IBNYR, elle est évaluée par segment à chaque date d'inventaire. Elle constitue un complément aux provisions D/D lorsque ces dernières sont jugées insuffisantes.

### **1.2. Régime du provisionnement IBNR**

Le tableau présente le régime du provisionnement des sinistres tardifs en Algérie et dans d'autres pays d'expérience.

**Tableau 1: Tableau représentatif du régime de provisionnement IBNR en Algérie et dans d'autres pays d'expérience**

Provisions pour Sinistres à Payer en Assurance Non Vie		
Pays	Définition	Mode de calcul
ALGERIE	<p>« Elle représente la valeur estimative des dépenses en principal et en frais y afférents, nécessaires au règlement de tous les sinistres déclarés et non payés à la date d'inventaire, y compris les capitaux constitutifs des rentes non encore mises à la charge de la société d'assurance. »</p>	<p>Elle est déterminée dossier par dossier et pour chaque période comptable, en prenant en considération son montant brut, excluant les déductions des recours à engager ainsi que des sinistres couverts par la réassurance ou la rétrocession.</p>
TUNISIE	<p>« La provision pour sinistres à payer correspond à une évaluation du montant qui sera versé postérieurement à la clôture de l'exercice au titre d'événements qui se sont réalisés antérieurement à la clôture de l'exercice. Les provisions comportent trois types de sinistres restant à payer :</p> <p>Les sinistres dont l'évaluation est définitive, connue et pour lesquels il ne demeure que le mouvement de trésorerie à générer ;</p> <p>Les sinistres pour lesquels l'évaluation n'est pas définitive et ayant fait ou non l'objet de règlements partiels ;</p> <p>Les sinistres survenus antérieurement à la clôture mais dont la survenance n'a pas été portée, à cette date, à la connaissance de l'entreprise. Il s'agit des sinistres tardifs. »</p>	<p>Le calcul de cette mesure est segmenté par catégorie de risque dans le contexte de la réassurance brute, prend en considération les éléments suivants :</p> <p>Une provision doit être établie pour chaque sinistre jusqu'à un certain montant prévisible des coûts futurs, en utilisant des méthodes statistiques approuvées si elles sont adéquates pour les risques.</p> <p>De plus, elle doit également prendre en compte les sinistres survenus mais non déclarés à la fin de la période comptable, en se basant sur l'historique du nombre et du montant des sinistres déclarés après la clôture du bilan.</p>

Provisions pour Sinistres à Payer en Assurance Non Vie		
Pays	Définition	Mode de calcul
	<p>« Cette provision correspond à la valeur estimative des dépenses pour sinistres non réglés et le montant des dépenses pour sinistres réglés restant à payer à la date de l'inventaire y compris les capitaux constitutifs de rentes non encore mises à la charge de l'entreprise.</p>	<p>La procédure d'évaluation de chaque dossier est complétée par une estimation du montant potentiel des sinistres survenus mais non déclarés à la date de l'inventaire.</p>

<b>MAROC</b>	Celle provision est calculée exercice par exercice et dossier par dossier pour son montant brut de réassurance et sans tenir compte des recours à exercer, augmentée d'une estimation du coût des sinistres survenus mais non déclarés à la date de l'inventaire. Elle est majorée d'un chargement de gestion de 5%. »	L'évaluation du nombre de sinistres survenus mais non déclarés à la date de l'inventaire repose sur les cadences des déclarations des sinistres observées par l'entreprise sur une période d'au moins cinq exercices précédant celui en cours.
<b>CIMA</b>	« Valeur estimative des dépenses en principal et en frais, tant internes qu'externes, nécessaires au règlement de tous les sinistres survenus et non payés, y compris les capitaux constitutifs des rentes non encore mises à la charge de l'entreprise. »	L'évaluation des sinistres déclarés se fait de manière dossier par dossier, prenant en compte toutes les dépenses externes individualisables, et elle est complétée par une estimation des coûts associés aux sinistres survenus mais non déclarés. L'estimation du coût déclarés tardivement est effectuée en utilisant la méthode de la cadence des déclarations des tardifs.

*Source : A partir des textes juridiques cités en référence.*

**- Article 6 de l'Ordonnance N°95-07 : Provision pour complément obligatoire aux provisions pour sinistres à payer :**

« La provision pour complément obligatoire aux provisions pour sinistres à payer est constituée en vue de suppléer une éventuelle insuffisance des provisions pour sinistres à payer résultant, notamment, de leur sous-évaluation de déclarations de sinistres après la clôture de l'exercice et des frais y afférents.

Cette provision est alimentée par un prélèvement de 5% du montant des provisions pour sinistres à payer.»

Afin de pallier d'éventuelles sous-évaluations des déclarations de sinistres après la clôture de l'exercice ou des frais y afférents, une provision complémentaire, constituée à partir d'un prélèvement de 5% des provisions pour sinistres à payer, vient renforcer ces dernières.

**Tableau 2 : Constitution de Provisions pour Sinistres à Payer\***

Provisions pour Sinistres à Payer	ALGERIE	TUNISIE	MAROC	CIMA
<b>Les provisions Dossier/Dossier</b>	+	+	+	+
<b>Les IBNR</b>	-	+	+	+

*Source : Elaboré par nos soins.*

Contrairement à d'autres pays, la législation en Algérie concernant les provisions techniques des sociétés d'assurance et/ou de réassurance n'inclut pas l'exigence de la constitution de la provision pour sinistres tardifs en tant que provision technique supplémentaire au niveau des provisions pour sinistres à payer.

**1.3. Méthodes d'estimation de la provision pour sinistres tardifs**

Nous présentons deux types de méthodes d'estimation connues sous le nom de méthodes d'estimation agrégée, qui sont très utilisées en assurance Non Vie permettant une estimation des provisions, à savoir :

- Les méthodes déterministes : Chain Ladder, London Chain, Bornhuetter Fergusson et Coût moyen ;
- Les méthodes stochastiques : Mack et Bootstrap.

**Tableau 3 : Tableau comparatif des méthodes présentées en assurance Non-Vie**

Méthode	Avantages	Inconvénients
<b>Déterministe</b>	<ul style="list-style-type: none"> <li>- Simplicité d'implémentation et d'interprétation des résultats ;</li> <li>- Calculs rapides ;</li> <li>- Robustesse face aux données atypique.</li> </ul>	<ul style="list-style-type: none"> <li>- Ne prend pas en compte l'incertitude inhérente aux données ;</li> <li>- Ne fournit pas d'information sur la distribution des provisions ;</li> </ul>
<b>Stochastique</b>	<ul style="list-style-type: none"> <li>- Prend en compte l'incertitude et permet d'estimer la distribution des provisions ;</li> <li>- Plus robuste.</li> </ul>	<ul style="list-style-type: none"> <li>- Plus complexe à implémenter et à interpréter les résultats ;</li> <li>- Calculs plus longs ;</li> <li>- Le risque d'erreur concernant la loi de distribution des paiements des sinistres conduisant à une estimation de la provision inexacte.</li> </ul>

*Source : Elaboré par nos soins.*

## 2. Méthodologie d'estimation de l'impact du provisionnement des IBNR de l'assurance Automobile

### 2.1. Sources et Description des données

Les données utilisées pour cette étude représentent les informations issues du portefeuille de l'assurance Automobile de la SAA réparties sur deux fichiers distincts. L'un de ces fichiers concerne un extrait des règlements, l'autre fichier représente un extrait des sinistres à payer.

En coopération avec la SAA Assurances, nous avons eu accès à 906 651 sinistres survenus et déclarés entre 2013 et 2022, vus au 31/12/2022 après l'épuration de la base brute. Chaque ligne représente une date d'observation du sinistre, allant de sa survenance jusqu'au 31/12/2022.

#### 2.1.1. Variables

Nous disposons des informations sur l'historique de la sinistralité de l'assuré durant la période d'observation qui contient 11 variables à savoir :

- ✓ Code d'agence ;
- ✓ Numéro de police ;
- ✓ Numéro de sinistre ;
- ✓ Date de survenance du sinistre ;
- ✓ Date de déclaration du sinistre ;
- ✓ Date de règlement (Date d'exercice) ;
- ✓ Garanties (RC, Défense et recours, Dommages) ;
- ✓ Nature de sinistre (Corporel, Matériel) ;
- ✓ Le règlement des sinistres à chaque date de vue (en dinars Algérien) ;
- ✓ Le montant de la SAP (en dinars Algérien) à chaque date de vue.

#### 1.2. Prétraitements des données

Avant d'effectuer des analyses statistiques, il est important de garantir l'intégrité, l'exhaustivité et la pertinence des données. Notre objectif est de garantir l'intégrité des données en vérifiant des données manquantes pour les variables essentielles, comme la date de survenance, et en assurant la cohérence des variables liées entre elles par nature. Nous avons développé une liste de contrôles à appliquer sur des variables essentielles, répertoriée ci-dessous :

**Contrôle n°1 :** Transformation des données du format reçu par les gestionnaires en forme triangulée. Les triangles ci-dessous ont été établis pour analyser les sinistres du portefeuille :

- Le triangle de règlements ;
- Le triangle de provisions ;
- Le triangle de charges sinistres (règlements sur l'année considérée + provisions).

**Contrôle n°2 :** Nous avons veillé à ce que les données restent inchangées d'une année à l'autre.

**Contrôle n°3 :** Les sinistres tardifs doivent être survenus au cours d'une année antérieure à l'année de déclaration, tandis que les sinistres non tardifs doivent survenir et être déclarés au cours de la même année. Nous avons vérifié la cohérence des tags avec les dates de survenance et de déclaration.

**Contrôle n°4 :** Nous avons vérifié que la dernière diagonale réconcilie avec les états financiers pour les montants des règlements, des provisions et des charges.

**Contrôle n°5 :** Nous avons examiné les signes des montants de règlements et des provisions en fonction de leur nature. En général, ces montants doivent être positifs. Toutefois, il est important de noter que pour les règlements, des valeurs négatives peuvent se présenter en raison d'annulations de règlements antérieurs.

## 2.2. Méthodologie de travail

L'objectif est d'estimer les sinistres tardifs liés à la branche Automobile au sein de la société SAA. En parallèle, elle vise à estimer leur impact sur les principaux éléments comptables de la compagnie d'assurance.

En ce sens, nous avons suivi la méthodologie d'estimation des IBNR lors d'une clôture réalisée par le groupe de travail de l'Institut des Actuaire.

### 2.2.1. Estimation de la provision IBNR par la méthode Chain Ladder

Cette technique projette les sinistres à l'ultime en s'appuyant sur l'évolution historique des données. Elle permet d'estimer les sinistres non encore déclarés en soustrayant les sinistres observés sur la dernière diagonale de l'ultime projeté.

Sur la période d'étude 2013-2022 (10 ans), les triangles de charges sont comme suit :

**Tableau 4 : Triangle de charges de la RC Corporelle en Millions DA**

RC Corporelle	Année d'observation										
	Année de survenance	0	1	2	3	4	5	6	7	8	9
2013	1 455,68	2 093,98	2 452,15	2 665,92	2 697,41	2 699,64	2 496,69	2 673,77	2 671,56	2 659,47	
2014	1 614,15	2 137,24	2 547,93	2 639,90	2 661,80	2 415,62	2 609,08	2 612,29	2 589,23		
2015	1 411,85	2 064,56	2 275,43	2 319,48	2 328,30	2 314,06	2 337,63	2 325,95			
2016	1 330,61	1 692,56	1 872,41	1 920,10	1 933,49	1 944,59	1 942,97				
2017	1 278,56	1 498,71	1 641,35	1 659,01	1 688,98	1 696,97					
2018	1 058,64	1 348,68	1 481,82	1 577,13	1 616,40						
2019	934,81	1 187,08	1 417,57	1 523,31							
2020	799,25	1 049,83	1 235,79								
2021	990,04	1 228,56									
2022	969,46										

*Source : Elaboré par nos soins sur la base des données communiquées par la SAA et en utilisant le logiciel EXCEL.*

**Tableau 5 : Triangle de charges de la Défense et Recours Corporel en Millions DA**

Défense et Recours Corporel	Année d'observation										
	Année de survenance	0	1	2	3	4	5	6	7	8	9
2013	48,26	74,75	103,36	121,68	130,51	134,92	136,06	137,14	138,15	139,12	
2014	46,80	72,40	102,35	119,34	127,76	130,06	132,31	133,65	134,40		
2015	43,70	67,15	93,18	105,75	111,84	113,63	116,37	117,78			
2016	34,32	55,38	76,15	85,77	91,29	95,29	97,00				
2017	28,37	48,36	65,83	73,39	80,53	84,62					
2018	29,32	42,69	55,56	67,32	72,10						
2019	26,48	34,58	51,37	64,01							
2020	20,24	28,78	44,24								
2021	23,20	32,41									

2022	24,77
------	-------

*Source : Elaboré par nos soins sur la base des données communiquées par la SAA et en utilisant le logiciel EXCEL.*

**Tableau 6 : Triangle de charges de la RC Matérielle en Millions DA**

RC Matérielle	Année d'observation									
	0	1	2	3	4	5	6	7	8	9
2013	2 251,39	2 479,61	2 632,01	2 712,40	3 234,27	3 260,41	3 271,56	3 263,61	3 275,12	3 279,87
2014	2 566,60	2 883,17	2 962,37	3 025,70	3 731,73	3 736,37	3 731,37	3 754,53	3 755,28	
2015	2 879,56	2 910,08	3 026,06	3 086,16	3 892,00	3 872,50	3 896,40	3 900,63		
2016	2 262,23	2 581,56	2 760,42	2 848,01	2 878,03	2 938,54	2 975,74			
2017	2 905,68	2 701,12	2 750,57	2 773,40	2 838,55	2 863,51				
2018	2 750,54	2 624,14	2 683,63	2 766,62	2 823,26					
2019	2 332,57	2 428,64	2 631,44	2 732,45						
2020	1 832,56	2 034,83	2 092,10							
2021	2 171,91	2 210,43								
2022	2 296,59									

*Source : Elaboré par nos soins sur la base des données communiquées par la SAA et en utilisant le logiciel EXCEL.*

**Tableau 7 : Triangle de charges de la Défense et Recours Matériel en Millions DA**

Défense et Recours Matériel	Année d'observation									
	0	1	2	3	4	5	6	7	8	9
2013	428,12	413,08	419,24	426,02	430,92	433,12	434,60	435,48	435,81	436,33
2014	488,01	498,24	506,29	512,69	516,19	518,83	520,05	520,94	521,76	
2015	483,35	503,10	512,08	519,16	522,41	525,13	527,19	528,43		
2016	468,83	487,54	494,98	501,36	503,08	505,49	507,24			
2017	455,64	473,50	480,38	485,23	489,23	491,70				
2018	480,76	468,68	470,38	474,50	477,75					
2019	494,52	484,58	488,21	492,69						
2020	408,34	405,06	407,10							
2021	464,59	454,90								
2022	488,07									

*Source : Elaboré par nos soins sur la base des données communiquées par la SAA et en utilisant le logiciel EXCEL.*

**Tableau 8 : Triangle de charges de Dommages Automobile en Millions DA**

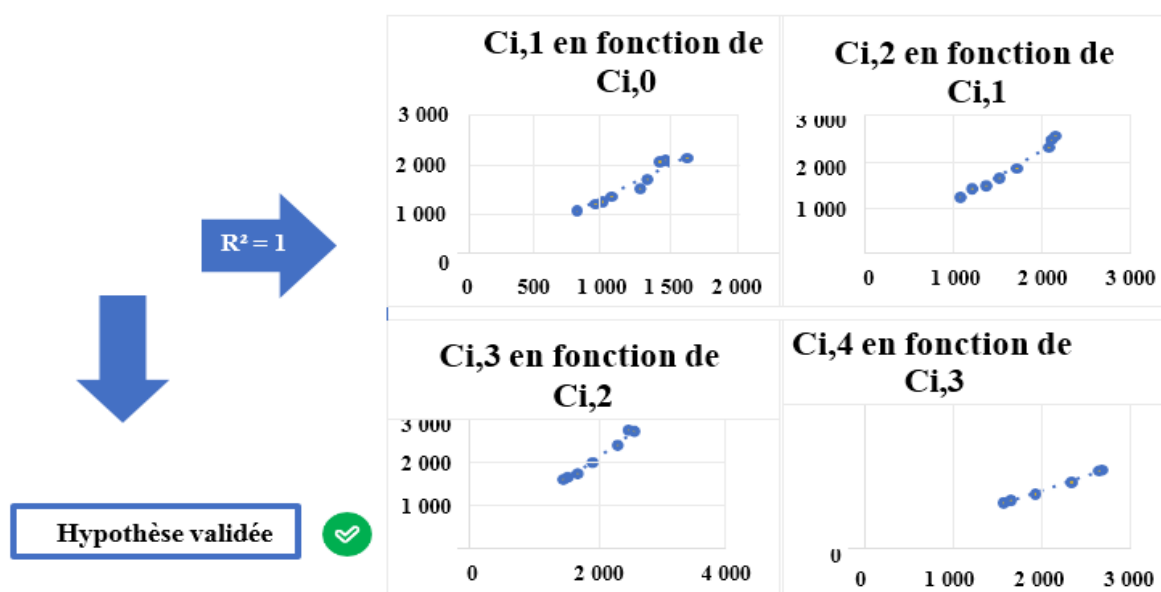
Dommages Auto	Année d'observation									
	0	1	2	3	4	5	6	7	8	9
2013	8 007,19	8 406,34	8 380,65	8 430,98	8 458,11	8 453,34	8 462,30	8 457,84	8 457,19	8 450,01
2014	8 227,34	8 643,15	8 689,29	8 699,34	8 699,11	8 711,65	8 716,81	8 701,74	8 704,73	
2015	8 151,98	8 486,28	8 472,67	8 481,39	8 504,22	8 510,03	8 520,89	8 508,72		
2016	6 998,47	7 334,15	7 361,15	7 353,34	7 376,01	7 356,40	7 355,54			
2017	7 056,86	7 337,82	7 291,34	7 282,87	7 290,21	7 302,41				
2018	7 427,53	7 768,00	7 747,82	7 752,81	7 732,48					
2019	8 217,29	8 535,37	8 559,42	8 531,06						
2020	6 676,23	6 919,81	6 904,38							
2021	7 801,58	7 866,01								
2022	8 057,50									

*Source : Elaboré par nos soins sur la base des données communiquées par la SAA et en utilisant le logiciel EXCEL.*

**a. Vérification des hypothèses**

Après avoir confirmé que les conditions requises par la méthode Chain Ladder sont respectées, nous appliquons cette méthode aux données du portefeuille en question. Pour chaque année fixée  $j$ , nous considérons un coefficient  $f_j$ ,  $C_{i,j+1} = f_j * C_{i,j}$ , avec les  $f_{ij}$  indépendants de l'année de survenance  $i$ . Pour vérifier cette hypothèse, nous examinerons si les couples  $(C_{i,j}, C_{i,j+1})$  montrent un alignement significatif sur une droite passant par l'origine, ce qui traduit la stabilité des rapports entre les montants. Notre analyse se concentre uniquement sur les quatre premières années de développement.

**Figure 2 : Validation de l'hypothèse de la méthode Chain Ladder : Alignement des couples (1/3)**

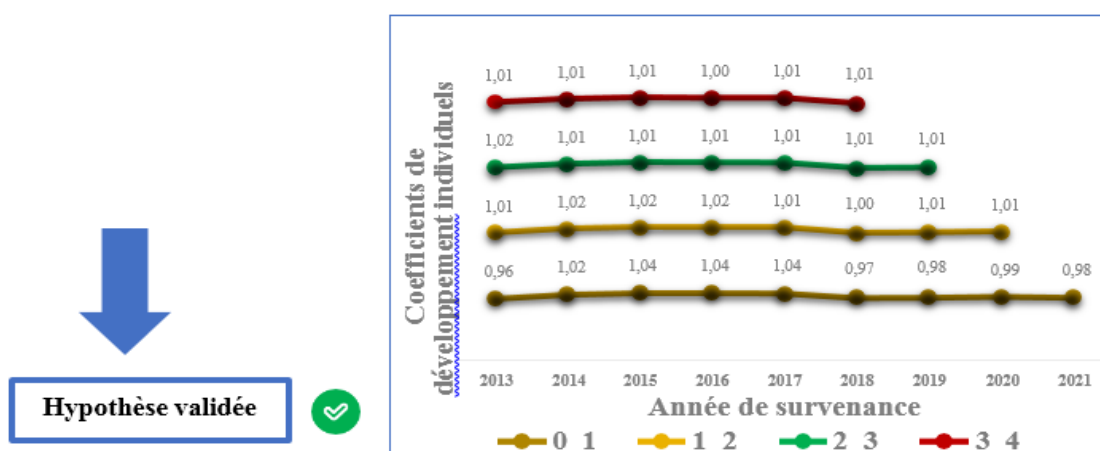


*Source : Extrait des résultats concernant les triangles du cas de sinistres corporels.*

Dans ce qui suit, nous validons notre modèle. Nous avons représenté graphiquement les relations entre les sinistres sur les quatre premières années de développement.

Ce qui montre premièrement une répartition linéaire. De plus, un coefficient de détermination ( $R^2$ ) proche de 1, suggérant un ajustement de qualité, indique qu'il y a une très forte corrélation linéaire entre les sinistres, montrant une cadence de montants des sinistres régulière d'une année de développement à une autre, tout en confirmant la 1<sup>ère</sup> hypothèse de Chain Ladder.

**Figure 3 : Validation de l'hypothèse de la méthode Chain Ladder : Stabilité des coefficients individuels (2/3)**



*Source : Extrait des résultats concernant les triangles du cas de sinistres corporels.*

Les graphiques ci-dessus montrent que les facteurs de développement individuels sont relativement stables, c'est-à-dire, la façon dont les sinistres évoluent d'une année à l'autre reste relativement constante au fil du temps, ce qui confirme que la 2ème hypothèse de Chain Ladder est globalement valide sur les années de développement observées, malgré une instabilité des coefficients individuels pour la première année. \*

Cette instabilité est due aux provisions forfaitaires nécessaires pour accumuler et réserver les informations sur les sinistres de manière appropriée. En ce qui concerne les années de développement à venir, les points montrent un alignement cohérent.

Par conséquent, nous pouvons dire que ces facteurs individuels sont indépendants de l'année de survenance *i*.

Etant donné que les valeurs observées dans le cas Corporel (Responsabilité Civile et Défense et Recours) au cours des dernières années sont très proches de 1, nous avons trouvé un facteur de queue (Tail Factor) égal à 1.

L'analyse exploratoire des données ne met en évidence aucun outlier, suggérant une grande stabilité dans la liquidation des sinistres et, par conséquent, une robustesse des facteurs de développement estimés par la méthode Chain Ladder.

La provision IBNR est estimée à partir des triangles de charges totales. Toutefois, il est important de noter que cette méthode reste simplifiée.

#### b. Résultats obtenus de la méthode de Chain Ladder

La provision totale IBNR s'élève à 3 350 Millions DA, résultant de la différence entre les chiffres connus au 31/12/2022 et des ultimes projetés pour déterminer les sommes dues au titre des sinistres survenus entre 2013 et 2022 (période d'étude de 10 ans). Comme le montrent les tableaux ci-après :

**Tableau 9 : Résultat du calcul de la provision IBNR sur le triangle de charges par la méthode Chain Ladder -RC Corporelle- en Millions DA**

RC Corporelle	Année d'observation										Charge Ultime	IBNR
Année de survenance	0	1	2	3	4	5	6	7	8	9		
2013	1 455,68	2 093,98	2 452,15	2 665,92	2 697,41	2 699,64	2 496,69	2 673,77	2 671,56	2 659,47	2 659,47	0,00
2014	1 614,15	2 137,24	2 547,93	2 639,90	2 661,80	2 415,62	2 609,08	2 612,29	2 589,23	2 577,51	2 577,51	-11,72
2015	1 411,85	2 064,56	2 275,43	2 319,48	2 328,30	2 314,06	2 337,63	2 325,95	2 314,83	2 304,35	2 304,35	-21,60
2016	1 330,61	1 692,56	1 872,41	1 920,10	1 933,49	1 944,59	1 942,97	1 986,98	1 977,49	1 968,53	1 968,53	25,56
2017	1 278,56	1 498,71	1 641,35	1 659,01	1 688,98	1 696,97	1 699,23	1 737,72	1 729,41	1 721,58	1 721,58	24,61
2018	1 058,64	1 348,68	1 481,82	1 577,13	1 616,40	1 582,23	1 584,33	1 620,22	1 612,48	1 605,18	1 605,18	-11,22
2019	934,81	1 187,08	1 417,57	1 523,31	1 540,57	1 508,00	1 510,00	1 544,21	1 536,83	1 529,87	1 529,87	6,57
2020	799,25	1 049,83	1 235,79	1 291,42	1 306,06	1 278,45	1 280,15	1 309,14	1 302,89	1 296,99	1 296,99	61,19
2021	990,04	1 228,56	1 402,59	1 465,73	1 482,34	1 451,00	1 452,93	1 485,84	1 478,74	1 472,05	1 472,05	243,49
2022	969,46	1 275,05	1 455,67	1 521,19	1 538,43	1 505,91	1 507,91	1 542,07	1 534,70	1 527,75	1 527,75	558,29
Cj	1,32	1,14	1,05	1,01	0,98	1,00	1,02	1,00	1,00			875,18

*Source : Elaboré par nos soins.*

\* Quant aux coefficients de développement individuels des années 0 à 9, nous constatons une fluctuation autour de la moyenne.



**Tableau 10 : Résultat du calcul de la provision IBNR sur le triangle de charges par la méthode Chain Ladder -Défense et Recours Corporel- en Millions DA**

Défense et Recours Corporel	Année d'observation										Charge Ultime	IBNR	
	0	1	2	3	4	5	6	7	8	9			
Année de survenance													
2013	48,26	74,75	103,36	121,68	130,51	134,92	136,06	137,14	138,15	139,12	139,12	0,00	
2014	46,80	72,40	102,35	119,34	127,76	130,06	132,31	133,65	134,40	135,35	135,35	0,95	
2015	43,70	67,15	93,18	105,75	111,84	113,63	116,37	117,78	118,54	119,38	119,38	1,60	
2016	34,32	55,38	76,15	85,77	91,29	95,29	97,00	97,97	98,60	99,30	99,30	2,30	
2017	28,37	48,36	65,83	73,39	80,53	84,62	86,02	86,87	87,44	88,05	88,05	3,44	
2018	29,32	42,69	55,56	67,32	72,10	74,30	75,53	76,28	76,78	77,32	77,32	5,22	
2019	26,48	34,58	51,37	64,02	68,57	70,67	71,84	72,56	73,02	73,54	73,54	9,52	
2020	20,24	28,78	44,24	51,47	55,13	56,82	57,76	58,33	58,71	59,12	59,12	14,88	
2021	23,20	32,41	45,25	52,63	56,38	58,10	59,07	59,65	60,04	60,46	60,46	28,05	
2022	24,77	37,61	52,50	61,07	65,42	67,42	68,54	69,22	69,67	70,16	70,16	45,39	
Cj	1,52	1,40	1,16	1,07	1,03	1,02	1,01	1,01	1,01			111,35	

Source : Elaboré par nos soins.

**Tableau 11 : Résultat du calcul de la provision IBNR sur le triangle de charges par la méthode Chain Ladder -RC Matérielle- en Millions DA**

RC Matérielle	Année d'observation										Charge Ultime	IBNR	
	0	1	2	3	4	5	6	7	8	9			
Année de survenance													
2013	2 251,39	2 479,61	2 632,01	2 712,40	3 234,27	3 260,41	3 271,56	3 263,61	3 275,12	3 279,87	3 279,87	0,00	
2014	2 566,60	2 883,17	2 962,37	3 025,70	3 731,73	3 736,37	3 731,37	3 754,53	3 755,28	3 760,73	3 760,73	5,45	
2015	2 879,56	2 910,08	3 026,06	3 086,16	3 892,00	3 872,50	3 896,40	3 900,63	3 907,45	3 913,12	3 913,12	12,49	
2016	2 262,23	2 581,56	2 760,42	2 848,01	2 878,03	2 938,54	2 975,74	2 981,05	2 986,26	2 990,59	2 990,59	14,85	
2017	2 905,68	2 701,12	2 750,57	2 773,40	2 838,55	2 863,51	2 877,45	2 882,59	2 887,63	2 891,81	2 891,81	28,31	
2018	2 750,54	2 624,14	2 683,63	2 766,62	2 823,26	2 839,75	2 853,57	2 858,67	2 863,66	2 867,82	2 867,82	44,55	
2019	2 332,57	2 428,64	2 631,44	2 732,45	3 079,40	3 097,38	3 112,47	3 118,02	3 123,47	3 128,00	3 128,00	395,55	
2020	1 832,56	2 034,83	2 092,10	2 145,70	2 418,15	2 432,27	2 444,11	2 448,48	2 452,76	2 456,31	2 456,31	364,22	
2021	2 171,91	2 210,43	2 306,32	2 365,41	2 665,76	2 681,32	2 694,38	2 699,19	2 703,90	2 707,83	2 707,83	497,39	
2022	2 296,59	2 390,80	2 494,51	2 558,42	2 883,28	2 900,11	2 914,23	2 919,44	2 924,54	2 928,78	2 928,78	632,19	
Cj	1,04	1,04	1,03	1,13	1,01	1,00	1,00	1,00	1,00			1 994,99	

Source : Elaboré par nos soins.

**Tableau 12 : Résultat du calcul de la provision IBNR sur le triangle de charges par la méthode Chain Ladder - Défense et Recours Matériel- en Millions DA**

Défense et Recours Matériel	Année d'observation										Charge Ultime	IBNR	
	0	1	2	3	4	5	6	7	8	9			
Année de survenance													
2013	428,12	413,08	419,24	426,02	430,92	433,12	434,60	435,48	435,81	436,33	436,33	0,00	
2014	488,01	498,24	506,29	512,69	516,19	518,83	520,05	520,94	521,76	522,39	522,39	0,63	
2015	483,35	503,10	512,08	519,16	522,41	525,13	527,19	528,43	529,06	529,70	529,70	1,27	
2016	468,83	487,54	494,98	501,36	503,08	505,49	507,24	508,27	508,88	509,50	509,50	2,25	
2017	455,64	473,50	480,38	485,23	489,23	491,70	493,31	494,32	494,91	495,50	495,50	3,81	
2018	480,76	468,68	470,38	474,50	477,75	480,16	481,74	482,72	483,29	483,87	483,87	6,13	
2019	494,52	484,58	488,21	492,69	496,18	498,68	500,32	501,34	501,94	502,54	502,54	9,85	
2020	408,34	405,06	407,10	411,94	414,85	416,95	418,32	419,17	419,67	420,17	420,17	13,07	
2021	464,59	454,90	460,37	465,85	469,14	471,51	473,06	474,02	474,58	475,16	475,16	20,25	
2022	488,07	490,01	495,90	501,79	505,34	507,89	509,56	510,59	511,20	511,82	511,82	23,75	
Cj	1,00	1,01	1,01	1,01	1,01	1,00	1,00	1,00	1,00			81,00	

Source : Elaboré par nos soins.

**Tableau 13 : Résultat du calcul de la provision IBNR sur le triangle de charges par la méthode Chain Ladder -Dommages Automobile- en Millions DA**

Dommages Automobile	Année d'observation										Charge Ultime	IBNR
	Année de survenance	0	1	2	3	4	5	6	7	8		
2013	8 007,19	8 406,34	8 380,65	8 430,98	8 458,11	8 453,34	8 462,30	8 457,84	8 457,19	8 450,01	8 450,01	0,00
2014	8 227,34	8 643,15	8 689,29	8 699,34	8 699,11	8 711,65	8 716,81	8 701,74	8 704,73	8 697,34	8 697,34	-7,39
2015	8 151,98	8 486,28	8 472,67	8 481,39	8 504,22	8 510,03	8 520,89	8 508,72	8 509,88	8 502,65	8 502,65	-6,06
2016	6 998,47	7 334,15	7 361,15	7 353,34	7 376,01	7 356,40	7 355,54	7 346,47	7 347,47	7 341,24	7 341,24	-14,31
2017	7 056,86	7 337,82	7 291,34	7 282,87	7 290,21	7 302,41	7 307,75	7 298,73	7 299,73	7 293,53	7 293,53	-8,88
2018	7 427,53	7 768,00	7 747,82	7 752,81	7 732,48	7 733,66	7 739,31	7 729,77	7 730,82	7 724,26	7 724,26	-8,22
2019	8 217,29	8 535,37	8 559,42	8 531,06	8 541,62	8 542,93	8 549,17	8 538,62	8 539,79	8 532,54	8 532,54	1,47
2020	6 676,23	6 919,81	6 904,38	6 907,97	6 916,52	6 917,58	6 922,63	6 914,10	6 915,04	6 909,17	6 909,17	4,79
2021	7 801,58	7 866,01	7 863,01	7 867,11	7 876,85	7 878,05	7 883,81	7 874,08	7 875,16	7 868,47	7 868,47	2,46
2022	8 057,50	8 378,61	8 375,42	8 379,78	8 390,16	8 391,44	8 397,57	8 387,21	8 388,36	8 381,23	8 381,23	323,73
Cj	1,04	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00			287,59

Source : Elaboré par nos soins.

### 2.2.2. Estimation de la Provision IBNR par la méthode du Bornhuetter-Ferguson

Compte tenu des limites de nos données, notamment de la non-disponibilité des primes acquises pour chaque garantie majeure de la branche Automobile, nous avons travaillé uniquement avec les primes acquises liées à l'ensemble de cette branche.

Cette approche s'appuie sur des estimations de la charge ultime obtenue par la méthode Chain Ladder, non seulement à partir des valeurs des primes acquises  $P_i$  pour chaque année de survenance étudiée, mais aussi sur une information exogène définie par le « Loss Ratio ».

**Tableau 14 : Synthèse des résultats obtenus à l'aide de la méthode de Bornhuetter-Ferguson pour l'ensemble de la branche Automobile en Millions DA**

Année de survenance	Charge Ultimes	Primes acquises	S/P	Ultime à priori	Provision BF
2013	14 965	28 771	52%	14 965	- 13
2014	15 692	29 075	54%	15 692	- 14
2015	15 364	29 329	52%	15 364	- 17
2016	12 910	28 348	46%	12 910	31
2017	12 494	27 795	45%	12 494	55
2018	12 759	28 357	45%	12 759	37
2019	13 785	28 676	48%	13 785	442
2020	11 187	26 005	46%	11 964	539
2021	12 706	25 404	46%	11 688	841
2022	13 625	27 384	46%	12 598	1 654
				Total provision BF	3 556

Source : Elaboré par nos soins à l'aide du logiciel EXCEL.

En intégrant les données externes  $P_i$  (les valeurs des primes acquises par année de survenance) et  $\phi_i$  (Loss ratio), ainsi qu'en tenant compte de l'estimation de charge ultime à priori, le montant de la provision de la branche Automobile s'élève à 3 555 Millions DA.

### 2.2.3. Estimation par méthode de Mack de la Provision IBNR

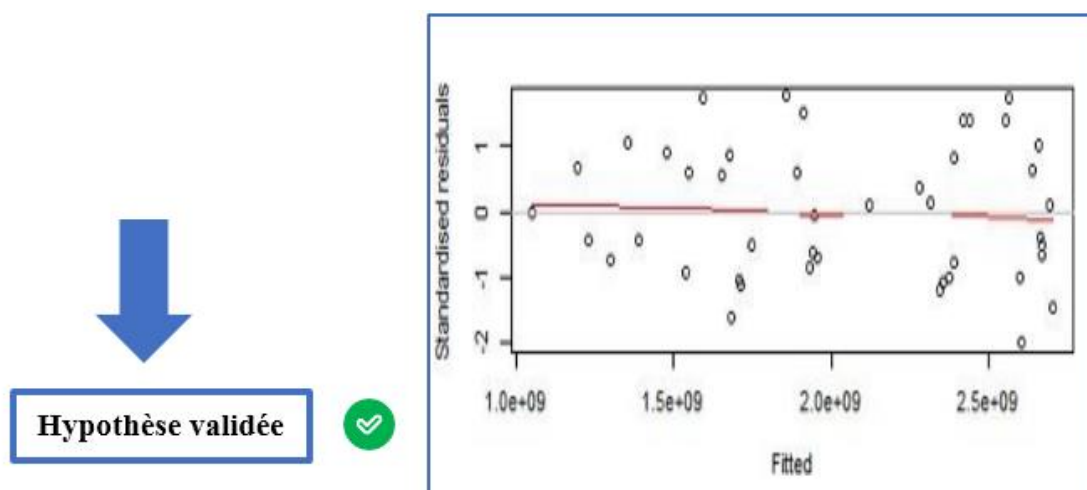
La méthode de Mack intègre l'incertitude dans la méthode déterministe Chain Ladder. La contribution principale de Thomas Mack à la méthode Chain Ladder réside dans la capacité à quantifier l'erreur de prédiction. Cette erreur est évaluée par la moyenne de l'erreur quadratique de prédiction MSEF, mesurant ainsi l'écart moyen entre les valeurs estimées et les valeurs réellement observées.

### a. Vérification des hypothèses

L'hypothèse d'indépendance des sinistres selon leur année de survenance peut être validée lorsque les coefficients de développement ligne par ligne ne présentent pas une dispersion excessive autour de leur médiane respective. Cette observation suggère que l'hypothèse d'indépendance est vérifiée. Dans notre analyse, les résultats antérieurs confirment que cette hypothèse est bien respectée.

La dernière hypothèse présente l'analyse des résidus standardisés qui concerne le modèle de Mack qui est la version stochastique de la méthode Chain Ladder. Comme le montre le graphique ci-après, ils prennent une forme aléatoire (ils ne montrent pas des tendances spécifiques). Autrement dit, les provisions retenues par ce modèle sont très proches de la réalité, ce qui indique que les hypothèses de Chain Ladder et de Mack sont bien respectées.

**Figure 4 : Validation de l'hypothèse de la méthode de Mack : Evolution des résidus standardisés en fonction de la provision estimée (3/3)**



*Source : Extrait des résultats concernant les triangles du cas de sinistres corporels*

### Remarque :

Les hypothèses des méthodes Chain Ladder et Mack sont validées pour tous les triangles considérés dans l'étude.

### a. Résultats obtenus de la méthode de Mack

En reprenant les concepts théoriques et les résultats obtenus avec la méthode Chain Ladder, nous retirons les estimations ci-après :

**Tableau 15 : Calcul des estimateurs des moindres carrés de  $f_j$  et  $\sigma_j^2$  et des erreurs quadratiques moyennes - RC Corporelle-**

Année de survenance	$f_j$	$\sigma_j^2$	$\hat{C}_{ln}$	$\hat{R}_i$	SEP ( $\hat{R}_i$ )
2013			2 659 469 332	0	
2014	1,32	11 328 574	2 577 511 983	-11 721 027	2 876 671
2015	1,14	3 274 776	2 304 352 078	-21 595 875	16 957 051
2016	1,05	1 748 921	1 968 534 387	25 563 691	104 014 770
2017	1,01	111 680	1 721 584 423	24 613 420	174 515 586
2018	0,98	4 475 953	1 605 175 744	-11 222 002	191 292 559
2019	1,00	10 325 066	1 529 871 865	6 565 106	186 608 448
2020	1,02	4 401 296	1 296 988 297	61 194 493	176 815 292
2021	1,00	84 519	1 472 049 127	243 485 994	202 245 940
2022	1,00	1 623	1 527 749 400	558 293 527	244 600 167

*Source : Sortie logiciel R.*

<b>Total Provision</b>	875 177 326
<b>Erreur de prédiction</b>	336 230 523
<b>IC (Log-Normale)</b>	[675 591 972 ; 985 220 651]
<b>CV</b>	38%

**Tableau 16 : Calcul des estimateurs des moindres carrés de  $f_j$  et  $\sigma_j$  et des erreurs quadratiques moyennes -Défense et Recours Corporel-**

Année de survenance	$f_j$	$\sigma_j^2$	$\hat{C}_{in}$	$\hat{R}_i$	SEP ( $\hat{R}_i$ )
2013			139 121 104	0	
2014	1,52	405 648	135 346 243	947 190	140 301
2015	1,40	194 142	119 377 271	1 597 505	224 474
2016	1,16	139 719	99 298 476	2 295 186	325 107
2017	1,07	14 813	88 053 142	3 435 746	798 538
2018	1,03	23 504	77 319 003	5 222 853	1 621 088
2019	1,02	5 230	73 539 204	9 523 110	1 922 726
2020	1,01	531	59 124 791	14 881 152	3 423 957
2021	1,01	199	60 463 225	28 053 992	4 909 727
2022	1,01	74	70 160 539	45 388 361	8 134 378

*Source : Sortie logiciel R.*

<b>Total Provision</b>	111 345 094
<b>Erreur de prédiction</b>	11 094 350
<b>IC (Log-Normale)</b>	[105 204 540 ; 112 516 529]
<b>CV</b>	9%

**Tableau 17 : Calcul des estimateurs des moindres carrés de  $f_j$  et  $\sigma_j$  et des erreurs quadratiques moyennes -RC Matérielle-**

Année de survenance	$f_j$	$\sigma_j^2$	$\hat{C}_{in}$	$\hat{R}_i$	SEP ( $\hat{R}_i$ )
2013			3 279 874 258	0	
2014	1,04	14 726 623	3 760 730 104	5 446 954	6 730 676
2015	1,04	1 502 153	3 913 120 174	12 485 346	12 875 913
2016	1,03	274 945	2 990 591 503	14 852 189	19 178 888
2017	1,13	40 212 883	2 891 814 304	28 305 975	27 266 346
2018	1,01	310 467	2 867 816 914	44 553 814	42 216 392
2019	1,00	111 909	3 128 000 076	395 549 792	365 167 712
2020	1,00	66 471	2 456 313 231	364 216 009	320 081 359
2021	1,00	19 328	2 707 825 825	497 391 637	345 394 050
2022	1,00	5 620	2 928 779 930	632 186 583	431 696 438

*Source : Sortie logiciel R.*

<b>Total Provision</b>	1 994 988 299
<b>Erreur de prédiction</b>	853 766 413
<b>IC (Log-Normale)</b>	[914 632 159 ; 2 734 977 837]
<b>CV</b>	42%

**Tableau 18 : Calcul des estimateurs des moindres carrés de  $f_j$  et  $\sigma_j$  et des erreurs quadratiques moyennes -Défense et Recours Matériel-**

Année de survenance	$f_j$	$\sigma_j^2$	$\hat{C}_{in}$	$\hat{R}_i$	SEP ( $\hat{R}_i$ )
2013			436 333 197	0	
2014	1,00	457 825	522 388 921	629 220	245 139
2015	1,01	14 244	529 698 033	1 269 593	438 017
2016	1,01	3 358	509 495 403	2 251 469	466 331
2017	1,01	3 213	495 502 731	3 805 282	593 524
2018	1,01	12	483 874 822	6 127 910	590 515
2019	1,00	231	502 540 718	9 847 291	1 504 775
2020	1,00	52	420 174 602	13 073 498	1 853 239
2021	1,00	159	475 155 900	20 252 185	3 419 478
2022	1,00	52	511 820 088	23 747 804	16 882 594

*Source : Sortie logiciel R.*

<b>Total Provision</b>	81 004 253
<b>Erreur de prédiction</b>	17 752 728
<b>IC (Log-Normale)</b>	[59 806 951 ; 88 707 958]
<b>CV</b>	21%

**Tableau 19 : Calcul des estimateurs des moindres carrés de  $f_j$  et  $\sigma_j$  et des erreurs quadratiques moyennes - Dommages Automobile-**

Année de survenance	$f_j$	$\sigma_j^2$	$\hat{C}_{in}$	$\hat{R}_i$	SEP ( $\hat{R}_i$ )
2013			8 450 010 199	0	
2014	1,04	1 293 917	8 697 337 267	-7 391 989	1 740 469
2015	1,00	126 546	8 502 653 226	-6 063 002	3 541 943
2016	1,00	70 466	7 341 235 449	-14 308 469	6 468 745
2017	1,00	41 155	7 293 529 949	-8 881 624	8 235 589
2018	1,00	24 089	7 724 257 316	-8 224 133	17 152 756
2019	1,00	2 963	8 532 537 143	1 474 350	27 270 870
2020	1,00	3 341	6 909 168 509	4 793 293	33 599 013
2021	1,00	757	7 868 471 067	2 457 561	49 280 379
2022	1,00	171	8 381 232 703	323 729 123	119 442 212

*Source : Sortie logiciel R.*

<b>Total Provision</b>	287 585 110
<b>Erreur de prédiction</b>	127 681 089
<b>IC (Log-Normale)</b>	[276 866 862 ; 442 686 722]
<b>CV</b>	44%

L'évolution de l'erreur standard est modérée au début, mais elle augmente progressivement avec le temps, devenant plus intense au cours des trois dernières années. Cela s'explique par un plus grand nombre d'estimations récentes, ce qui augmente le risque d'erreur.

La précision de la provision estimée selon la méthode Chain Ladder pourrait être améliorée si les erreurs des derniers exercices n'avaient pas accru le risque d'erreur.

Après analyse des résultats, il apparaît que le modèle de Mack est partiellement compatible avec la méthode du Chain Ladder, mettant en lumière une incertitude modérée quant à l'estimation des provisions par cette méthode.

#### 2.2.4. Estimation par la méthode Bootstrap

Le principe repose sur la simulation de nombreux échantillons de taille N, permettant ainsi de calculer une moyenne des provisions et d'établir un intervalle de confiance. Dans le but d'obtenir des résultats plus fiables, nous avons effectué plusieurs simulations à partir du modèle de Chain Ladder, la méthode permet d'obtenir les résultats suivants :

**Tableau 20 : Simulations par Bootstrap à l'aide de Chain Ladder sur le triangle de charges en RC Corporelle**

Nombre de simulations	Quantile à 25%	Moyenne	Quantile à 75%	Ecart-type
10 000	675 876 888	875 178 200	1 739 828 270	336 332 308
100 000	680 405 111	875 284 393	1 970 301 710	336 760 000
500 000	679 309 089	875 208 122	1 926 937 764	336 636 576

*Source : Sortie logiciel R.*

**Tableau 21 : Simulations par Bootstrap à l'aide de Chain Ladder sur le triangle de charges en Défense et Recours Corporel**

Nombre de simulations	Quantile à 25%	Moyenne	Quantile à 75%	Ecart-type
10 000	108 153 578	111 621 952	118 272 037	11 395 306
100 000	108 853 823	112 194 101	120 321 286	11 775 471
500 000	108 477 627	111 815 685	119 480 293	11 692 462

*Source : Sortie logiciel R.*

**Tableau 22 : Simulations par Bootstrap à l'aide de Chain Ladder sur le triangle de charges en RC Matérielle**

Nombre de simulations	Quantile à 25%	Moyenne	Quantile à 75%	Ecart-type
10 000	994 271 018	2 022 047 007	2 916 927 218	871 215 985
100 000	994 594 847	2 075 137 848	2 999 738 932	888 251 543
500 000	994 464 311	2 024 944 936	2 930 133 068	880 066 496

*Source : Sortie logiciel R.*

**Tableau 23 : Simulations par Bootstrap à l'aide de Chain Ladder sur le triangle de charges en Défense et Recours Matériel en Millions DA**

Nombre de simulations	Quantile à 25%	Moyenne	Quantile à 75%	Ecart-type
10 000	61 567 309	81 935 734	124 308 890	17 759 741
100 000	64 008 844	82 370 528	134 755 010	17 823 415
500 000	62 876 888	81 968 405	129 956 948	17 804 378

*Source : Sortie logiciel R.*

**Tableau 24 : Simulations par Bootstrap à l'aide de Chain Ladder sur le triangle de charges en Dommages Automobile**

Nombre de simulations	Quantile à 25%	Moyenne	Quantile à 75%	Ecart-type
10 000	285 766 245	287 585 740	524 212 437	127 781 377
100 000	286 499 412	287 636 137	550 912 969	127 872 606
500 000	285 801 609	287 585 782	542 197 829	127 868 991

*Source : Sortie logiciel R.*

Plus le nombre de simulations augmente, plus la moyenne obtenue se stabilise. Il est préférable d'utiliser un modèle avec un grand nombre de simulations conformément à la loi des grands nombres. Ainsi, les résultats seront analysés sur la base de 500 000 simulations.

Les résultats semblent proches de ceux obtenus avec la méthode de Mack, ce qui est cohérent car le Bootstrap utilise les mêmes coefficients de développement.

**Tableau 25 : Résultats de méthode Bootstrap**

	Bootstrap (Modèle Gamma)	
	Provision IBNR estimée	Erreur de prédiction (SE)
RC Corporelle	875 208 122	336 636 576
Défense et Recours Corporel	111 815 685	11 692 462
RC Matérielle	2 024 944 936	880 066 496
Défense et Recours Matériel	81 968 405	17 804 378
Dommages Automobile	287 585 782	127 868 991

*Source : Sortie logiciel R.*

Les résultats obtenus révèlent que l'erreur de prédiction mesurée par l'écart-type est supérieure à celle observée avec le modèle de Mack, ce qui indique que la méthode de Mack est plus appropriée que Bootstrap.

Étant donné que la méthode de Bootstrap est non paramétrique, elle permet de calculer les quantiles directement à partir de la distribution observée, sans la nécessité des hypothèses sur la fonction de distribution, ce qui constitue un de ses avantages.

Par ailleurs, la méthode pour l'intervalle de confiance consiste à étudier la distribution de la provision pour pouvoir établir un intervalle de confiance.

Nous approximons la distribution de la provision  $\hat{R}_i$  moyennant une distribution log- normale. L'intervalle de confiance à 95% est défini par les bornes suivantes :

**Tableau 26 : Les bornes d'un intervalle de confiance à 5% par garantie**

	Intervalle de confiance	Ecart
RC Corporelle	[650 541 885 ; 2 076 692 261]	1 426 150 376
Défense et Recours Corporel	[106 794 410 ; 130 005 970]	23 211 560
RC Matérielle	[945 461 928 ; 2 934 008 048]	1 988 546 120
Défense et Recours Matériel	[60 717 657 ; 144 577 835]	83 860 178
Dommages Automobile	[286 029 747 ; 560 044 244]	274 014 497

*Source : Sortie logiciel R.*

L'intervalle de confiance de Bootstrap est plus étendu que celui du modèle de Mack, indiquant une plus grande incertitude sur l'estimation, l'écart entre les deux bornes pour Mack est inférieur aux celles de Bootstrap.

### 2.2.5. Estimation par la méthode Chain Ladder appliquée au nombre de sinistres

Les sinistres classés comme IBNR au 31/12/N sont ceux pour lesquels aucun paiement n'a été effectué entre leur date de survenance et le 31/12/N. Bien que le dossier puisse être ouvert par les services de gestion, c'est le premier paiement qui détermine si le sinistre est connu ou non.



L'application de la méthode Chain Ladder aboutit aux résultats suivants :

**Tableau 27 : Estimation du nombre des dossiers inconnus par la méthode Chain Ladder pour la période 2013 – 2022**

Dossiers inconnus					
Année de survenance	RC Corporelle	Défense et Recours Corporel	RC Matérielle	Défense et Recours Matériel	Dommages Automobile
2013	0	0	0	0	0
2014	1	1	3	3	1
2015	1	1	11	11	5
2016	4	4	21	21	11
2017	4	5	37	37	17
2018	7	7	65	65	27
2019	13	13	266	266	96
2020	22	22	291	291	104
2021	61	61	498	498	187
2022	151	150	1 151	1 151	585
<b>Total</b>	<b>264</b>	<b>264</b>	<b>2 343</b>	<b>2 343</b>	<b>1 033</b>

*Source : Elaboré par nos soins à l'aide du logiciel EXCEL.*

En théorie, le coût moyen de la survenance N est calculé en divisant la charge totale des prestations et des provisions au 31/12/N par le nombre de sinistres indemnisés. Cependant, cette méthode surestime le coût réel en raison d'une règle de sélection prudente pour les sinistres, entraînant une provision excessive pour certains dossiers au 31/12/N.

Pour atténuer cet impact tout en restant prudent dans nos estimations, le coût moyen des événements inconnus de 2022 est calculé en prenant la moyenne des coûts moyens des sinistres les plus stables sur les quatre dernières années de leur survenance.

**Tableau 28 : Résultats des IBNYR et des IBNER pour l'exercice 2022 pour chaque garantie majeure**

	Dossiers inconnus	Coût moyen	Total IBNYR	Total IBNER
<b>RC Corporelle</b>	264	2 466 038	651 034 016	224 143 310
<b>Défense et Recours Corporel</b>	264	297 526	78 546 864	32 798 230
<b>RC Matérielle</b>	2 343	107 807	252 590 993	1 742 397 306
<b>Défense et Recours Matériel</b>	2 343	14 283	33 464 560	47 539 693
<b>Dommages Automobile</b>	1 033	102 000	105 366 000	182 219 110

*Source : Elaboré par nos soins à l'aide du logiciel EXCEL.*

Comme le montre le tableau ci-dessus, le contexte de la SAA se caractérise par des sinistres strictement tardifs (IBNYR) plus élevés en RC Corporelle qu'en RC Matérielle et les sinistres déclarés mais insuffisamment provisionnés (IBNER) sont plus élevés en RC Matérielle.

### 2.3. Analyse comparative des différents résultats obtenus

En référence aux différentes méthodes d'estimation utilisées, il en ressort la synthèse comparative suivante :

- Les prédictions semblent globalement proches entre les différents modèles stochastiques ;
- Le modèle de Mack semble prédire une provision IBNR moins importante par rapport au modèle du Bootstrap ;
- Globalement, les modèles semblent fournir des prédictions compétitives avec le Chain Ladder ;
- D'un point de vue agrégé, toutes les prédictions au global ont une erreur modérée ;
- Le modèle qui semble commettre généralement le moins d'erreur est encore une fois le modèle de Mack.

Tableau 29 : Récapitulatif des résultats en Millions DA

Méthode	Provisions estimées en DA
Chain Ladder	3 350
London Chain	3 359
Bornhuetter-Ferguson	3 556
Mack	3 350
Bootstrap	3 381

Source : Elaboré par nos soins à l'aide du logiciel EXCEL.

## 2.4. L'estimation de l'impact du provisionnement des IBNR de l'assurance Automobile

Tableau 30 : Résultats de la provision IBNR pour les exercices 2021 et 2022 en Millions DA

Garantie	IBNR 2021	5% PSAP 2021	IBNR 2022	5% PSAP 2022
<b>RC Corporelle</b>	886	233	875	207
<b>Défense et Recours Corporel</b>	101	55	111	36
<b>RC Matérielle</b>	1 998	154	1 995	179
<b>Défense et Recours Matériel</b>	75	8	81	5
<b>Dommages Automobile</b>	286	134	288	156
<b>Total</b>	<b>3 346</b>	<b>584</b>	<b>3 350</b>	<b>583</b>

Source : Elaboré par nos soins.

Le montant total des IBNR à la clôture de l'exercice est supérieur à celui de l'ouverture, ce qui est logique. En raison des ajustements effectués pendant l'année 2022, les IBNR de 2021 spécifiquement liés à la Responsabilité Civile Automobile ont diminué, entraînant ainsi une reprise.

Par ailleurs, il est clair que 5 % de la PSAP pour renforcer les provisions pour sinistres à payer ne sont pas suffisants pour couvrir éventuellement la provision IBNR. Il est donc souhaitable d'estimer la provision IBNR par des méthodes actuarielles.

Tableau 31 : Résultats de Ratio IBNR en Millions DA

Garantie	IBNR 2021	PSAP constituées 2021	IBNR 2022	PSAP constituées 2022	Ratio IBNR 2021	Ratio IBNR 2022
<b>RC Corporelle</b>	886	4 663	875	4 138	19%	21%
<b>Défense et Recours Corporel</b>	101	1 093	111	631	9%	18%
<b>RC Matérielle</b>	1 998	3 084	1 995	3 572	65%	56%
<b>Défense et Recours Matériel</b>	75	167	81	191	45%	42%
<b>Dommages Automobile</b>	286	2 677	288	3 129	11%	9%
<b>Total</b>	<b>3 346</b>	<b>11 685</b>	<b>3 350</b>	<b>11 661</b>		

Source : Elaboré par nos soins.

Le ratio IBNR est un indicateur clé de la santé financière d'une compagnie d'assurance. Il mesure l'ampleur des sinistres qui sont survenus mais qui n'ont pas encore été déclarés par rapport aux sinistres qui ont été déclarés et pour lesquels des provisions ont été constituées.

Un ratio IBNR élevé peut indiquer que la compagnie s'attend à une proportion importante de sinistres futurs non déclarés, tandis qu'un ratio plus bas peut suggérer une moindre anticipation de sinistres futurs non déclarés.

Les ratios IBNR par rapport aux PSAP constituées ont montré une tendance à la hausse pour le cas Corporel, puis à la baisse pour le cas Matériel. Par exemple, pour la RC Matérielle, le ratio a diminué de 65% en 2021 à 56% en 2022, et pour la Défense et Recours Matériel, il est passé de 45% à 42%. Ces changements reflètent une meilleure gestion des provisions, bien que certains segments, comme la RC Corporelle et la Défense et Recours Corporel, aient vu une augmentation significative de leur ratio IBNR, passant respectivement de 19% à 21% et de 9% à 18%, indiquant des ajustements des réévaluations spécifiques.

Le tableau ci-dessous présente une comparaison du Résultat Net de l'exercice avant et après la prise en compte de la provision IBNR.\*

**Tableau 32 : Comparaison du Résultat Net de l'exercice 2022 avant et après la prise en compte de la provision IBNR en Millions DA**

DESIGNATION	AVANT	APRES
<b>I - PRIMES ACQUISES A L'EXERCICE</b>	23 409	23 409
<b>II - PRESTATIONS(SINISTRE) DE L'EXERCICE</b>	12 083	12 104
<b>III - COMMISSIONS DE REASSURANCE</b>	1 145	1 145
<b>IV - MARGE D'ASSURANCE NETTE (I - II + III)</b>	12 471	12 451
<b>V - RESULTAT TECHNIQUE OPERATIONNEL</b>	1 245	1 224
<b>VI - RESULTAT FINANCIER</b>	2 268	2 268
<b>VII - RESULTAT ORDINAIRE AVANT IMPOTS (V + VI)</b>	3 513	3 492
<b>VIII - RESULTAT NET DURESULTAT ORDINAIRE</b>	3 148	3 127
<b>X - RESULTAT NET DE L'EXERCICE</b>	<b>3 148</b>	<b>3 127</b>

*Source : Elaboré par nos soins.*

Nous constatons une augmentation de la provision IBNR passant de 3 346 Millions DA en 2021 à 3 350 Millions DA en 2022, car la provision IBNR de clôture est supérieure à celle d'ouverture, ce qui réduit la Marge de Solvabilité Nette et, par conséquent, le Résultat Net de l'exercice.

Cette baisse est due à la prise en compte de la variation de la provision IBNR au niveau des sinistres et des charges techniques sur les opérations directes de la SAA.\*

\* Nous supposons que l'IBNR de la branche Automobile représente près de 90 % chez SAA

\* Nous n'avons pas pris en considération le calcul de la variation de la provision IBNR liée au réassureur, qui doit être déterminée par ce dernier, car nous ne disposons pas des informations nécessaires.

## Conclusion

Dans le cadre de cet article, nous avons estimé la provision pour IBNR à l'aide des méthodes actuarielles dont l'objectif est d'estimer l'impact de l'intégration de la provision IBNR sur les principaux indicateurs de la compagnie d'assurance, en l'occurrence la SAA. Notre approche représente une amélioration significative de la méthodologie actuelle en renforçant la stabilité financière et assurant la conformité réglementaire.

Notre analyse a révélé que la prise en compte de la provision IBNR a un impact significatif sur les principaux éléments comptables de la compagnie d'assurance, à savoir une diminution de 20 Millions DA (soit 0,7%) du résultat net et de la marge d'assurance nette pour l'exercice 2022. D'autre part, nous avons observé que l'intégration des IBNR dans les calculs de solvabilité est importante pour la gestion des risques de sinistralité, entraînant une augmentation des passifs de 20 Millions DA (soit 0,7%) sur la période 2013-2022 et l'absence de cette provision peut entraîner une sous-évaluation des engagements financiers futurs de la compagnie d'assurance.

En guise de conclusion, l'introduction de l'obligation de la provision IBNR en Algérie renforcerait la solvabilité des compagnies d'assurances en réduisant les risques de sous-estimation des passifs et en améliorant la protection des assurés.

## Recommandations

Dans une divergence avec les normes ou les exigences actuarielles observées dans la plupart des autres pays, la législation Algérienne en matière d'assurances n'impose pas aux assureurs la constitution de provisions pour sinistres inconnus (IBNR).

Nous proposons de réviser la réglementation en vigueur concernant les provisions techniques afin de rendre obligatoire la constitution de la provision IBNR.

Introduire cette exigence garantirait une couverture plus complète des engagements futurs des assureurs, en anticipant les sinistres non encore déclarés. Cette mesure renforcerait la stabilité financière du secteur de l'assurance en minimisant les risques de sous-évaluation des passifs et en assurant une meilleure protection des assurés.

Par ailleurs, il est nécessaire la mise en place de requêtes systèmes afin d'extraire les primes acquises et les IBNR par année de survenance et par segmentation par garantie. Cette démarche vise à approfondir l'analyse, en s'appuyant sur un historique d'au moins cinq ans pour les branches à cycle court et d'au moins dix ans pour celles à cycle long.

## Références Bibliographiques

---

- Article n°1 de l'Ordonnance n°74-15 du 30 janvier 1974.
- Article n°6 du Décret exécutif n° 13-114 du 28 Mars 2013 relatif aux engagements réglementés des sociétés d'assurance et/ou de réassurance Algériennes.
- Article n°20 du Décret exécutif n° 13-114 du 28 Mars 2013 relatif aux engagements réglementés des sociétés d'assurance et/ou de réassurance Algériennes.
- Article n°28 modifié par la Circulaire du président de l'Autorité de contrôle des assurances et de la prévoyance sociale n° AS/03/2019 du 30 Octobre 2019.
- Article n°334.8 du Code des Assurances des Etats Membres de la CIMA du 10 juillet 1992.
- Norme Comptable Tunisienne relative aux provisions techniques dans les entreprises d'assurance et/ou de réassurance NCT 29 du 1 Janvier 2001.
- AMOUCHE L., LOBE LOBAS L., et TANGUY B. (2023), « Processus d'estimation des IBNR lors d'une clôture », Institut des Actuaire, Lyon 1, P. 7.
- BOCQUAIRE E., CAMUS M. (2019), "Les grands principes de l'actuariat", éditions l'Argus de l'Assurance.
- CHARBONNIER J. (2012), « L'assurance du risque automobile », Editions Larcier, P. 94.
- Bureau Spécialisé de Tarification en Assurance (2023), « Etude sur les provisions techniques en Assurances, Provision pour IBNR », Algérie, P. 9.
- COULBAUT F., ELIASHBERG C. et LATRASSE M. (2002). « Les grands principes de l'assurance ». 5ème édition. Paris: Edition l'Argus.
- DENUIT M., CHARPENTIER A. (2005), « Mathématiques de l'Assurance Non-Vie », Tome II : Tarification et Provisionnement, Edition ECONOMICA, P 341-342.
- DENUIT M., CHARPENTIER A.(2004). Mathématiques de l'assurance non-vie, Tome I : principes fondamentaux de théorie du risque. édition Economica.
- Guide de provisionnement des sinistres en assurance non-vie (2023), Institut des Actuaire, Lyon 1.
- Rapport Annuel de la SAA (2017, 2018, 2019, 2020, 2021, 2022), disponible sur : [www.uar.dz](http://www.uar.dz) Rapport d'Activité des Assurances en Algérie (2020, 2021, 2022), disponible sur : [www.uar.dz](http://www.uar.dz) Rapport de gestion de la SAA (2022), disponible sur : [www.uar.dz](http://www.uar.dz)

## L'impact du risque de liquidité sur la performance bancaire: Cas des banques tunisiennes

Arwa MASMOUDI  
Arab Tunisian Bank-ATB



### Résumé

Cet article examine l'impact du risque de liquidité sur la performance bancaire en Tunisie, évaluée à travers la marge nette d'intérêt. Afin d'atteindre cet objectif, nous avons utilisé des données de panel de 10 banques représentatives du secteur bancaire tunisien, pour la période allant de 2003 à 2022. Les résultats empiriques montrent que le ratio crédits/dépôts exerce un impact significativement positif sur la performance financière des banques tunisiennes. Par ailleurs, le ratio des capitaux propres par rapport au total des actifs ainsi que la concentration du marché bancaire présentent un impact positif et significatif sur la performance de ces banques. En revanche, les prêts non-performants et la taille de la banque ont un effet négatif et significatif sur la marge nette d'intérêt.

Les résultats de cette étude pourraient revêtir une grande importance pour les directeurs de banque, afin d'élaborer des stratégies appropriées pour gérer le risque de liquidité et améliorer leurs performances.

**Mots clés** : Risque de liquidité, ratio de liquidité, ratio de transformation, performance bancaire, banques tunisiennes, données de panel.

### Introduction

Ces dernières décennies ont été caractérisées par une accélération de la mondialisation, un développement intensif des marchés financiers, des innovations financières rapides, ainsi que l'émergence d'une économie mondiale intégrée. Ces changements ont eu un impact profond sur le secteur bancaire mondial et sa performance, entraînant des perturbations et une succession des turbulences, en particulier sur le plan financier.

En effet, les banques, en leur qualité d'institutions financières, jouent un rôle crucial dans le financement et le développement de toute économie en exerçant les fonctions d'intermédiation financière. Cela se manifeste par la collecte de dépôts auprès des agents disposant de capacité de financement et la mise à disposition de crédits aux entreprises ainsi qu'aux particuliers, facilitant ainsi le financement de leurs investissements. De cette façon, la performance des banques représente un pilier fondamental de la prospérité économique, du développement financier, et même du bien-être social d'un pays.

Par conséquent, la surveillance rigoureuse de la performance, de la santé et de la solidité financière des banques revêt une importance accrue. Ces institutions font face à des risques pouvant sérieusement compromettre leur efficacité, entraînant ainsi des crises susceptibles d'affecter l'ensemble du système bancaire, voire financier, en raison de l'interconnexion entre toutes les composantes du système financier.

De tels chocs ont la potentialité de déclencher un effondrement global de l'économie, étant donné l'importance cruciale du poids et des rôles des banques, ce qui accroît le risque de propagation des crises financières dans l'économie réelle.

À ce sujet, la crise financière de 2008-2009 a démontré que le risque de liquidité représente une source significative d'instabilité pour les institutions bancaires. La hausse du risque de non-remboursement des prêts hypothécaires aux États-Unis a conduit à une diminution de la liquidité sur ces marchés. Cette crise a suscité de nombreuses réflexions sur la question du risque de liquidité, en mettant en évidence qu'il s'agit d'un risque majeur qui doit être évalué, géré et maîtrisé de manière plus efficace.

Divers travaux antérieurs se sont intéressés à la relation entre le risque de liquidité et la performance financière des banques. La littérature financière consacrée à ce sujet est riche, et les résultats empiriques sont divergents. En effet, certains auteurs suggèrent que le risque de liquidité exerce un effet négatif sur la performance, tandis que d'autres affirment que ce risque rend les banques plus performantes, alors que d'autres chercheurs n'ont pas identifié un impact significatif. De cette relation contradictoire, nous tirons la problématique de notre étude : Quel est l'impact du risque de liquidité sur la performance des banques tunisiennes ?

Notre recherche contribue à enrichir la littérature empirique existante, notamment dans le domaine examinant la relation entre le risque de liquidité et la performance bancaire, une relation par laquelle il n'y a pas de consensus général sur les résultats. Cela souligne l'importance d'approfondir la recherche sur le risque de liquidité qui peut perturber la rentabilité du secteur bancaire tunisien, étant donnée la forte dépendance de son économie à l'égard de ce secteur pour le financement de ses activités.

En nous inspirant du modèle de Hakimi et Zaghdoudi (2017), nous allons mener une étude comparative en actualisant les données et en intégrant de nouvelles variables telles que la révolution tunisienne et la masse monétaire.

Cet article est organisé de la manière suivante : la première section aborde une revue de la littérature concernant l'impact du risque de liquidité sur la performance des banques. La deuxième section décrit la méthodologie de recherche, et la troisième section présente les résultats ainsi que leur interprétation.

## 1. Revue de la littérature

Diverses études ont mis l'accent sur l'analyse des facteurs qui affectent la performance de la banque, notamment le risque de liquidité. Le lien entre ce risque et la performance des institutions bancaires est relativement complexe. Certaines recherches indiquent qu'un niveau accru de risque de liquidité améliore la performance bancaire en générant des bénéfices grâce aux intérêts élevés. Cependant, d'autres études soulignent que cela diminue l'efficacité de la banque en raison du coût élevé du capital. En effet, plusieurs auteurs ont constaté une relation positive, tandis que d'autres ont trouvé une relation négative ; certains ont même noté des relations à la fois positives et négatives, et d'autres n'ont pas relevé de relation significative. Ainsi, deux perspectives contradictoires émergent concernant la relation entre le risque de liquidité et la performance des banques :

- Le risque de liquidité contribue à améliorer la performance des banques : la plupart des recherches menées en Europe (Bourke (1989), Rudhani et Balaj (2019)), en Asie (Alzorqan (2014), Alim et al (2021)), Huong et al (2021)) et en Afrique (Ferrouhi (2014), Musiega et al (2017)) analysent cet impact, en utilisant les variables ROA et ROE comme mesures de performance. Les résultats montrent qu'un risque de liquidité plus élevé est généralement associé à une meilleure performance des banques.

Huong et al (2021) proposent également une perspective différente en utilisant le gap de liquidité comme indicateur de risque de liquidité, par rapport à d'autres recherches. En examinant 171 banques

dans 9 pays d'Asie du Sud-Est<sup>24</sup> et en analysant des données de panel déséquilibré pour la période de 2004 à 2016, les auteurs ont montré que dans les conditions normales, la majorité des banques ayant une bonne performance, présentent un risque de liquidité élevé.

Par ailleurs, l'étude réalisée par Shen et al (2009) dans des pays développés a analysé des données de panel non équilibrées concernant les banques commerciales de 12 pays entre 1994 et 2006. En explorant la relation entre le risque de liquidité et la performance des banques à Taiwan, ils ont établi que ce risque est positivement associé à la performance bancaire, mesurée par la marge nette d'intérêt. Cela indique que les banques avec des niveaux élevés d'actifs illiquides, sous forme de prêts, peuvent générer des revenus d'intérêts plus importants.

Quant aux Chowdhury et al (2016), ils ont étudié l'effet du risque de liquidité sur la marge nette d'intérêts de 7 banques conventionnelles au Bangladesh sur la période 2011-2015. En utilisant la marge nette d'intérêts en tant qu'indicateur de performance bancaire et moyennant une analyse de régression, les résultats de cette étude ont prouvé que le ratio crédits/dépôts a un impact positif et statistiquement significatif sur la performance des banques étudiées. Cela montre que plus les crédits et les avances accordés sont importants à l'égard des dépôts des clients, plus la marge nette d'intérêts des banques est élevée.

- Le risque de liquidité entraîne une baisse de la performance bancaire : Les études menées en Europe (Petria et al (2015), Ndoka et al (2017)), en Asie (Tabari et al (2013), Chowdhury et Zaman (2018), Hacini et al (2021)), dans la région MENA (Abdelaziz et al (2022)) et en Afrique (Muriithi et Waweru (2017), Yahaya et al (2022), El Mahdy (2023)) se sont penchées sur l'effet du risque de liquidité sur la performance des banques, mesurée à travers les indicateurs ROA et ROE. Ces recherches révèlent que le risque de liquidité est un facteur ayant un effet négatif sur la performance des institutions bancaires.

Arif et Nauman Anees (2012), ainsi que Ndoka et al (2017), ont utilisé le gap de liquidité en tant qu'indicateur du risque de liquidité dans leurs recherches. Leurs résultats révèlent que ce risque représente l'un des facteurs les plus influents sur la performance bancaire, ayant un impact négatif.

Muriithi et Waweru (2017) ont étudié 43 banques commerciales au Kenya entre 2005 et 2014, et ont constaté que le ratio structurel de liquidité à long terme, en tant qu'indicateur du risque de liquidité, nuit à la rentabilité bancaire en raison des rendements faibles associés aux actifs liquides nécessaires pour répondre aux exigences réglementaires. En outre, une insuffisance de liquidité empêche les banques d'accéder à des fonds à coût raisonnable et entraîne un coût d'opportunité qui impacte également leur rentabilité.

Chen et al (2018) ont étudié les banques de 12 économies avancées entre 1994 et 2006 et ont découvert que le ratio de déficit de financement par rapport aux actifs totaux est négativement lié à la rentabilité des banques, mesurée par le ROAA et le ROAE. Un déficit de financement plus important contraint les banques à utiliser des actifs liquides ou à recourir à des financements externes, augmentant ainsi leurs coûts et réduisant leur rentabilité.

En réponse aux problèmes de risque de liquidité découlant de la crise financière des subprimes, Ly (2015), Huong et al (2021) et Chen et al (2021) ont constaté qu'entre 2007 et 2009, le risque de liquidité a entraîné une diminution de la probabilité de survie des banques, ainsi que leur marge nette d'intérêt et leur ROA.

---

<sup>24</sup> Le Brunei, le Cambodge, l'Indonésie, le Laos, le Myanmar, la Malaisie, les Philippines, la Thaïlande et le Viêt Nam.



En outre, certaines études ne montrent aucun lien entre le risque de liquidité et la performance bancaire, comme celle de Khalid et al (2019) qui ont analysé les banques commerciales du Bangladesh de 2010 à 2017, et dont les résultats indiquent que la liquidité n'a pas d'impact significatif sur la rentabilité des capitaux propres ni sur la rentabilité des actifs des 31 banques étudiées. En revanche, l'étude de Rahman et Saeed (2015) ainsi que celle de Kalimashi et al (2022) révèlent que les effets du risque de liquidité sur les performances des banques sont ambigus et dépendent des mesures de performance et de risque de liquidité utilisées.

Bordeleau et Graham (2010), en utilisant une régression non linéaire sur un échantillon de 55 banques américaines et 10 banques canadiennes de 1997 à 2009, ont observé une relation positive entre le risque de liquidité et la performance bancaire jusqu'à un certain seuil d'actifs liquides, après lequel la relation devient négative. Ils suggèrent également que la liquidité et la performance bancaire dépendent non seulement du fonctionnement interne de la banque, mais aussi de l'état de l'économie, notant que les banques avec une faible liquidité profitent de coûts financiers réduits.

Dans la même optique, Ebenezer et al (2019) ont étudié 63 banques commerciales des pays de l'ASEAN sur la période 2009-2017 et ont montré que le ratio crédit/dépôt a un effet positif sur le rendement des actifs, bien qu'il expose les banques à un risque de liquidité. Toutefois, l'étude révèle que le risque de liquidité, mesuré par les ratios crédit/dépôt et actif liquide/actif total, a un impact négatif sur le rendement des capitaux propres.

À leurs tours, en analysant comment les normes de Bâle 3 vont influencer la relation entre la performance des institutions bancaires et le risque de liquidité, Giordana et Schumacher (2013) ont souligné que le respect des normes de liquidité introduites par la Bâle ralentit l'octroi de crédits et influe de manière négative le résultat des banques ayant un portefeuille à faible risque. Dans ce sens, en utilisant un échantillon de 921 banques en Europe occidentale de 1996 à 2010 et en appliquant la méthodologie de GMM, Dietrich et al (2014) montrent que le NSFR n'a aucune influence statistiquement significative sur le rendement des actifs et des capitaux propres et la marge nette d'intérêt.

De même, Golubeva et al (2019) ont étudié l'impact du risque de liquidité sur la rentabilité des banques après l'adoption de la réglementation Bâle 3, en se basant sur un échantillon de 45 banques européennes entre 2014 et 2017. Leurs résultats montrent qu'il n'existe pas de relation significative entre le ratio de liquidité à court terme (LCR) et les indicateurs de rentabilité analysés. Plus récemment encore, Setiyono et Naufa (2020) ont analysé l'impact du ratio NSFR sur la performance et le risque des banques pendant la période 2007-2018. Ils ont découvert que la liquidité des banques affecte négativement leur performance, car une conservation élevée des liquidités entraîne une diminution des prêts et, par conséquent, des bénéfices.

## 2. Méthodologie

### 2.1. Echantillon de l'étude

En tenant compte d'un échantillon de 10 banques tunisiennes qui sont cotées à la BVMT dont chacune de leurs variables est de fréquence annuelle qui a été observée pendant la période s'étendant de 2003 à 2022, correspondant ainsi à un horizon de 20 ans avec un total de 200 observations. Nous avons choisi la période d'étude en fonction de la disponibilité des données et des événements marquants qui ont affecté les banques tunisiennes notamment la crise des subprimes (2007-2008), la révolution de Janvier 2011, la poursuite des réformes et la privatisation.

## 2.2. Sources des données

Nous avons construit notre base de données pour l'échantillon en utilisant les rapports annuels et les états financiers des banques, publiés sur le site du Conseil de Marché Financier (CMF) et le site de la Bourse des Valeurs Mobilières de Tunis (BVMT). Les données concernant les variables macroéconomiques sont recueillies à partir du site de la banque mondiale et celui de la Banque Centrale de Tunisie (BCT).

## 2.3. Présentation des variables

- **Variable dépendante**
  - **La performance bancaire**

Plusieurs variables sont utilisées pour évaluer la performance des banques : La marge nette d'intérêt « NIM » (Hakimi et Zaghoudi (2017)), la rentabilité des capitaux propres « ROE » (Hacini et al (2021), Abdelaziz et al (2022)), la rentabilité des actifs « ROA » (Rudhani et Balaj (2019), Khalid et al (2019)). Dans le cadre de notre recherche, nous avons opté pour l'utilisation de la marge nette d'intérêt (MNI) en tant qu'indicateur clé de performance comme dans les travaux de Chowdhury et al (2016), Hakimi et Zaghoudi (2017), Chen et al (2018), Madhuwanthi et Morawakage (2019), Huong et al (2021) et Chen et al (2021).

Le ratio de la marge nette d'intérêt (MNI) : La marge nette d'intérêt représente la rentabilité fondamentale de la banque, résultant de ses activités principales, à savoir la collecte de dépôts et l'octroi de crédits. En d'autres termes, ce ratio offre un aperçu de la capacité de la banque à générer des bénéfices à partir de ses activités d'intermédiation bancaires essentielles.

Ce ratio est déterminé selon la formule suivante :

$$MNI = \frac{\text{Intérêts perçus} - \text{Intérêts servis}}{\text{Total Actifs}} \quad (2.1)$$

- **Variables indépendantes**


### a) Variables spécifiques aux banques

Le risque de liquidité au sein d'une banque se réfère à la situation où cette institution ne puisse pas satisfaire pleinement ou partiellement les besoins de ses déposants dans un délai donné. Ce risque constitue la principale variable indépendante que notre étude cherche à évaluer quant à son impact sur la performance financière des banques.

Dans le cadre de notre analyse, nous avons choisi le ratio LTD, qui représente le rapport entre le total des crédits et le total des dépôts, en tant qu'outil de mesure de la vulnérabilité de la banque face au risque de liquidité. Alzorqan (2014), Ogilo et Mugenyah (2015), Chowdhury et al (2016), Hakimi et Zaghoudi (2017), Ogilo et al (2018), Zaghoudi (2019), Ebenezer et al (2019) et Kalimashi et al (2022) ont également utilisé ce proxy.

L'évolution du risque de liquidité des 10 banques cotées qui composent notre échantillon sur la période de 2003 à 2022 est représenté dans le graphique 1.

**Graphique 1 : Évolution du ratio Crédits/Dépôts moyen des 10 banques de l'échantillon entre 2003 et 2022 (en %)**



*Source : Elaboré par l'auteure*

Le ratio crédits/dépôts des 10 banques tunisiennes étudiées a affiché une tendance à la baisse pendant la période 2003-2009, tout en maintenant un niveau supérieur à 80%. À partir de 2009, le ratio de risque de liquidité moyen a commencé à augmenter, atteignant 128% en 2018.

À la suite à l'instauration en novembre 2018 d'une norme prudentielle imposant une limite de 120% pour le ratio LTD, ce dernier a amorcé une trajectoire à la baisse. Cette diminution a contribué à renforcer la liquidité et à freiner la croissance des emplois bancaires en particulier, en ce qui concerne l'octroi de crédits. Ainsi, il est clair que les répercussions de la réduction du ratio LTD par les banques se sont maintenues, se stabilisant à 105% en 2022.

La littérature sur la relation entre le risque de liquidité et la performance bancaire présente des résultats ambigus. Les études de Shen et al (2009), Chowdhury et al (2016), Chowdhury et Zaman (2018), Madhuwanthi et Morawakage (2019) et Alim et al (2021) ont prouvé que le risque de liquidité a un effet positif sur la performance des banques. En revanche, d'autres chercheurs, à l'instar d'Arif et al (2012), Marozva (2015), Hakimi et Zaghdoudi (2017), Ndoka et al (2017), Muriithi et Waweru (2017), Hacini et al (2021) et Chen et al (2021) ont soutenu une perspective opposée, suggérant que le risque de liquidité a un impact négatif sur la performance bancaire lorsque les ressources sont mal allouées.

En conséquence, nous avançons les deux hypothèses suivantes :

- Hypothèse (1) : Le risque de liquidité a un effet positif sur la performance financière des banques tunisiennes.
- Hypothèse (2) : Le risque de liquidité a un effet négatif sur la performance financière des banques tunisiennes.

#### ➤ **Risque de crédit**

Le risque de crédit constitue une autre variable permettant d'expliquer la performance des institutions financières. Pour les banques, ce risque découle essentiellement de leurs activités de crédit. Dans ce contexte, diverses variables ont été développées pour évaluer le risque de crédit. Dans notre étude, nous avons opté pour le ratio utilisé dans les études de Dincer et al (2011), Tabari et al (2013), Nisar et al (2018), Simoens et Vander Vennet (2021) et Yahaya et al (2022), à savoir le ratio des

prêts non-performants (NPL). Ce ratio NPL s'avère être un indicateur robuste pour mesurer le risque de crédit au sein des institutions bancaires.

Miller et Noulas (1997), Athanoglou et al (2008), Sangmi et Nazir (2010), Tabari et al (2013), Ayaydin et Karakaya (2014), Lee et al (2015), Zhang et al (2016), Chen et al (2018), Partovi et Matousek (2019), Huong et al (2021) et Yahaya et al (2022), ont démontré un lien négatif entre le risque de crédit et la rentabilité. Cette relation s'explique de manière simple : lorsque les créances classées augmentent, cela signale un risque d'insolvabilité des débiteurs, ce qui peut entraîner une diminution des revenus, affectant ainsi négativement la rentabilité. De ce fait, notre troisième hypothèse postule que : Le risque de crédit a une influence négative sur la performance financière de la banque.

#### ➤ **Taille de la banque**

La taille de la banque constitue l'un des facteurs majeurs ayant un impact significatif sur sa performance. En effet, cet indicateur exerce une influence considérable sur la rentabilité d'une institution bancaire, dans la mesure où les banques de plus grandes tailles ont la capacité de réaliser d'importantes économies d'échelle, ce qui a un impact positif sur leur rentabilité.

À ce niveau, nous visons à intégrer cette variable dans notre modèle économétrique à travers le logarithme naturel du total des actifs de la banque. De nombreux auteurs ont adopté cette variable dans leurs études, parmi lesquels Pasiouras et al (2007), Menicucci et Paolucci (2016), Kawshala et Panditharathna (2017), Abobakr (2018) et Huong et al (2021) mettant en évidence que la taille de la banque est l'un des principaux facteurs influençant positivement la rentabilité bancaire. D'où notre quatrième hypothèse suppose que : Plus la taille de la banque est importante, plus elle est performante.

#### ➤ **Ratio de capital**

Le ratio de capital d'une institution bancaire, est un facteur crucial qui influe sur sa performance. Ce ratio met en lumière dans quelle mesure les fonds propres de la banque sont utilisés pour couvrir les actifs à risque. De fait, avoir un niveau élevé de capitaux propres constitue un indicateur très favorable pour le marché, démontrant la solidité financière et la solvabilité de la banque. En outre, un ratio élevé indique une diminution du risque de faillite, ce qui permet à la banque d'obtenir des financements à moindre coût, favorisant ainsi des bénéfices plus importants. En revanche, un ratio faible signifie que la banque ne dispose pas de ressources adéquates pour faire face à la dépréciation de la valeur de ses actifs (García-Herrero et al (2009) et Goddard et al (2010)).

Plusieurs recherches menées par Anbar et Alper (2011), Ayaydin et Karakaya (2014), Ferrouhi (2014), Marozva (2015), Lee et al (2015) et Chen et al (2018), ont mis en évidence que les banques qui affichent les meilleures performances sont celles qui maintiennent un ratio élevé des capitaux propres par rapport à leurs actifs. Ainsi, notre cinquième hypothèse postule que : Le ratio de capital a une influence positive sur la performance financière de la banque.

#### ➤ **L'indice de Herfindahl-Hirschman**

La mesure de concentration du marché repose sur l'Indice Herfindahl-Hirschman (IHH), un indicateur calculé en sommant les carrés des parts de marché par rapport à l'ensemble des actifs. De nombreuses études ont été menées pour analyser le lien entre la concentration du marché et la performance des banques. Ainsi, pour tester cette relation, nous nous sommes basés sur l'étude de Hakimi et Zaghdoudi (2017), qui ont révélé une relation positive entre la concentration et la marge net d'intérêt des banques tunisiennes. Selon ces chercheurs, une concentration bancaire plus élevée est associée à des profits plus importants, ce qui se traduit par de meilleures performances pour les banques tunisiennes. D'où notre sixième hypothèse suppose que : La concentration du marché a un impact positif sur la performance bancaire.

## b) Variables macroéconomiques et financières

### ➤ La masse monétaire

La masse monétaire désigne la quantité de monnaie en circulation dans l'économie à un moment précis et elle évolue en parallèle avec les mouvements de l'activité économique. Lorsque la masse monétaire augmente, signifiant qu'il y a une plus grande quantité de monnaie en circulation, les banques peuvent bénéficier de liquidités supplémentaires. Cela leur permet de financer de nouveaux prêts ou d'investir ces fonds de manière rentable, par exemple en investissant sur les marchés financiers. En conséquence, une masse monétaire en croissance peut contribuer à améliorer la performance financière des banques.

Al-Qudah et Jaradat (2013) et Huong et al (2021) ont testé cette variable dans leurs études. Donc, ce serait intéressant d'évaluer l'impact de la masse monétaire sur la performance financière des banques tunisiennes. Nous développons ainsi notre septième hypothèse comme suit : La masse monétaire affecte positivement la performance bancaire

### ➤ La croissance économique

La croissance économique est couramment mesurée par le taux de croissance annuel du produit intérieur brut, un indicateur largement adopté dans les études empiriques pour analyser comment la conjoncture économique du pays impacte l'activité et la performance des institutions bancaires. L'étude antérieure menée par Tan et al (2017) a démontré que la croissance économique favorise la rentabilité des banques en stimulant l'expansion des crédits et la réduction des taux de défaillance des clients, tout en encourageant la consommation, l'épargne et les investissements. Dès lors, nous définissons notre huitième hypothèse comme suit : La croissance économique a une influence positive sur la performance bancaire.

### ➤ La crise financière internationale (2009)

La crise financière engendre une grande volatilité dans le secteur financier, créant des turbulences sur les marchés bancaires et financiers, ce qui peut entraîner la défaillance des banques et des institutions financières, présentant ainsi un risque de contagion pour l'ensemble du système financier. La crise des subprimes a eu des répercussions sur la plupart des systèmes bancaires des pays développés. Cette variable explicative a été incluse dans l'étude de Hakimi et Zaghdoudi (2017), laquelle a confirmé que la crise financière mondiale a un effet négatif et significatif sur la performance financière des banques tunisiennes. Ainsi, nous définissons notre neuvième hypothèse comme suit : La crise financière internationale affecte négativement la performance bancaire.

### ➤ La révolution tunisienne

Cette variable muette capte l'effet de la révolution tunisienne, prenant la valeur 1 pendant la période 2011-2014, sinon 0. De manière générale, il est possible de conclure que la révolution tunisienne a initialement eu un impact négatif sur la performance financière des banques, en raison de l'instabilité et de l'incertitude qui ont suivi les événements de 2010-2011. El Fodil (2019) a prouvé que la révolution tunisienne a des conséquences négatives persistantes sur la performance du secteur bancaire. Par conséquent, nous développons notre dixième hypothèse comme suit : La révolution tunisienne a un impact négatif sur la performance bancaire.

## 2.4. Spécification du modèle

Notre modèle économétrique s'inspire des travaux de Hakimi et Zaghdoudi (2017), auquel nous avons ajouté la variable de la révolution tunisienne et remplacé le taux d'inflation par la variable masse monétaire. Il s'écrit comme suit :

$$MNI_{it} = \beta_0 + \beta_1 LIQR_{i,t} + \beta_2 SIZE_{i,t} + \beta_3 CRIDR_{i,t} + \beta_4 CAP_{i,t} + \beta_5 IHH_{i,t} + \beta_6 CRISIS_{i,t} + \beta_7 REVOL_{i,t} + \beta_8 GPIB_{i,t} + \beta_9 M2_{i,t} + \varepsilon_{i,t}$$

Où :

- $i = 1 \dots 10$  banques ;
- $t = 2003$  jusqu'à  $2022$  ;
- $MNI_{it}$  : La marge nette d'intérêt de la banque  $i$  à l'année  $t$  ;  $LIQR_{i,t}$  : Ratio du risque de liquidité de la banque  $i$  à l'année  $t$  ;  $SIZE_{i,t}$  : Taille de la banque  $i$  à l'année  $t$  ;  $CRIDR_{i,t}$  : Ratio du risque de crédit de la banque  $i$  à l'année  $t$  ;  $CAP_{i,t}$  : Ratio de capital de la banque  $i$  à l'année  $t$  ;  $IHH_{i,t}$  : L'indice IHH de la banque  $i$  à l'année  $t$  ;  $CRISIS_{i,t}$  : La crise des subprimes ;  $REVOL_{i,t}$  : La révolution tunisienne ;  $GPIB_{i,t}$  : La croissance économique de l'année  $t$  ;  $M2_{i,t}$  : La masse monétaire de l'année  $t$  ;  $\beta$  : Les coefficients associés aux variables explicatives ;  $\varepsilon_{i,t}$  : Le terme d'erreur.

## 2.5. Méthodes d'estimation

En se basant sur les données de panel de 10 banques tunisiennes pour la période allant de 2003 à 2022, nous effectuons les tests préliminaires d'hétéroscédasticité (Breush-Pagan), d'autocorrélation (Woodridge), le test d'homogénéité (Test de spécification de Fisher) et le test Hausman qui nous mène à choisir le modèle à effet aléatoire pour notre régression en utilisant la méthode des moindres carrés généralisées permettant de corriger l'hétéroscédasticité et l'autocorrélation.

## 3. Présentation des résultats

Nous présentons les résultats des statistiques descriptives dans un premier temps et dans un deuxième temps nous présentons les résultats des régressions effectuées.

### 3.1. Statistiques descriptives

Tableau 1 : Statistiques descriptives

Variables	Observations(N)	Moyenne	Ecart type	Minimum	Maximum
MNI	200	0.0249372	0.0071272	0.0076826	0.0415811
LIQR	200	1.036422	0.1831769	0.5418894	1.5
CRIDR	200	0.1394885	0.0858731	0.0371	0.447
SIZE	200	15.40712	0.647626	13.84419	16.8655
CAP	200	0.0910418	0.0313706	-0.0162253	0.1748179
IHH	200	0.1145388	0.0031004	0.1103981	0.1201695
CRISIS	200	0.15	0.3579675	0	1
REVOL	200	0.2	0.4010038	0	1
M2	200	10.71432	0.5437392	9.760483	11.57198
GPIB	200	0.025485	0.0324458	-0.0882	0.0671

Source : Calcul de l'auteure à partir du logiciel Stata 16

L'analyse des résultats issus des statistiques descriptives pour chaque variable intégrée dans notre modèle révèle que :

La variable à expliquer (MNI) atteint une valeur moyenne de 2,49% sur la période de 2003 à 2022, avec un minimum de 0,76% et un maximum de 4,15%. La fourchette entre le minimum et le maximum démontre de manière évidente l'ampleur des disparités de rentabilité au sein des banques tunisiennes. La dispersion autour de la moyenne de cette variable est très faible et il est à l'ordre de 0,0071.

En ce qui concerne la variable explicative (LIQR) qui est le « risque de liquidité », sa moyenne s'élève à 103,64%, avec une valeur minimale de 54,18% et une valeur maximale de 150%. Son écart-type est à l'ordre de 0,1831.

La variable (SIZE) affiche une moyenne de 15,40 sur la période allant de 2003 à 2022, avec un minimum de 13,84 et un maximum de 16,86. Cela suggère que les banques incluses dans notre échantillon sont principalement de petite taille par rapport aux banques internationales. La déviation standard de cette variable s'élève à environ 0,6476, indiquant une dispersion significative par rapport à la moyenne.

Pour la variable explicative (CRIDR), qui évalue le risque de crédit, sa moyenne se situe à 13,94% sur la période de 2003 à 2022, avec un minimum de 3,71% et un maximum de 44,7%. Son écart-type est à l'ordre de 0,0858.

Le ratio moyen de capital est à l'ordre de 9,10%. En moyenne, cela indique que les banques tunisiennes qui composent notre échantillon sont modérément capitalisées. La variable (CAP) affiche une valeur minimale de -1,62%, suggérant que certaines banques ont une capitalisation insuffisante, tandis que la valeur maximale atteint 17,48%. Elle est caractérisée par une dispersion autour de la moyenne à l'ordre de 0,0313.

Concernant la variable indice de concentration (IHH), sa moyenne s'établit autour de 0,114, avec un minimum de 0,110 et un maximum de 0,120. Sa déviation standard égale à 0,0031.

Pour la crise financière internationale, elle se situe en moyenne autour de 0,15, avec un écart-type de 0,357. Quant à la révolution tunisienne, elle admet une moyenne dont la valeur égale à 0,20 et une dispersion autour de la moyenne est de 0,401.

Pour ce qui est de la variable macroéconomique, le taux de croissance du PIB (GPIB) a affiché une moyenne de 2,54%, avec une valeur minimale de -8,82 % et une valeur maximale de 6,71%. Sa dispersion autour de la moyenne est de 0,0324. La deuxième variable concerne la masse monétaire, dont la moyenne s'élève à 10,71 sur la période de 2003 à 2022, avec un minimum de 9,76 et un maximum de 11,57. L'écart-type associé est de l'ordre de 0,54373.

### 3.2. Résultats de modèle de régression

Le tableau ci-dessous expose les résultats empiriques de notre régression à effet aléatoire en utilisant des données de panel sur la période couvrant de 2003 à 2022.

Tableau 2 : Résultats d'estimation

Variables	Coefficient	Z	P>z
LIQR	0.0054996*	2.91	0.004
CRDR	-0.0331674*	-8.10	0.000
SIZE	-0.0160185*	-8.23	0.000
CAP	0.0471154*	3.51	0.000
IHH	0.3535971*	3.95	0.000
CRISIS	0.0005607	0.79	0.430
REVOL	0.0008321	1.24	0.215
M2	0.013825*	7.53	0.000
GPIB	-0.0024288	-0.31	0.759
Constante	0.0775591*	4.57	0.000
R-squared	Within = 0.5150 Between = 0.1663 Overall = 0.2049		
Test	Wald Chi2 (9) = 181.92		
Prob	Prob > Chi2 = 0.0000*		

Source : Calcul de l'auteure à partir du logiciel Stata 16

\*, \*\* et \*\*\* désignent une signification aux seuils de 1%, 5% et 10%. (\*\*\*)  $p < 0.01$ , \*\*  $p < 0.05$ , \*  $p < 0.1$ ).

En se référant au tableau 2, nous pouvons mettre en évidence les contestations suivantes :

En commençant par la variable risque de liquidité, nous constatons que le coefficient correspondant est significativement positif au seuil de 1%. Cela signifie qu'une augmentation de 1% du risque de liquidité se traduit par une hausse de 0,0054% de la marge nette d'intérêt. Cet impact positif peut être expliqué par le fait que les banques cherchent à maximiser leurs revenus en diversifiant leurs actifs, par exemple en accordant des prêts plus risqués, ce qui peut entraîner une augmentation du ratio LTD. L'objectif sous-jacent est d'accroître la marge nette d'intérêt en tant que mesure de performance financière, en profitant des prêts générant des rendements plus élevés.

En outre, les banques tunisiennes mettent en œuvre une stratégie visant à maximiser leur marge d'intérêts en prolongeant la maturité de leurs actifs, entraînant ainsi une augmentation de leur taux de transformation (LTD) et, par conséquent de leur risque de liquidité. Néanmoins, cette stratégie s'est avérée bénéfique en générant une marge d'intérêts plus élevée, contribuant ainsi à l'amélioration de leur performance bancaire. Par conséquent, dans le contexte tunisien, nous constatons que l'exposition au risque de liquidité améliore la marge nette d'intérêt des banques, telle que préconise notre hypothèse H1.

Nos résultats rejoignent ceux de Shen et al (2009), Chowdhury et al (2016), ainsi que Madhuwanthi et Morawakage (2019), qui ont mis en évidence que le risque de liquidité entraîne une augmentation significative de la performance bancaire. Néanmoins, ces constatations semblent être en contradiction avec les études de Demirguc-Kunt et al (2003), Marozva (2015), Ly (2015), Hakimi et Zaghdoudi (2017), Huong et al (2021) et Chen et al (2021), qui révèlent une relation négative entre le risque de



liquidité et la performance des institutions bancaires. Cette disparité de résultats peut être attribuée à des différences dans l'impact du risque de liquidité en fonction de la région ou de la période étudiée.

Par la suite, nous avons constaté que la variable risque de crédit a un effet significatif au seuil de 1% sur la marge nette d'intérêt. Conformément à nos attentes, le coefficient associé à cette variable est négatif, indiquant que lorsque le risque de crédit augmente de 1%, la performance bancaire mesurée par la marge nette d'intérêt diminue de 0,0331%. Par conséquent, nous validons notre troisième hypothèse.

Cet impact négatif peut être expliqué par le fait qu'une augmentation du taux des prêts non-performants entraîne une augmentation des provisions, ce qui, à son tour, diminue les bénéfices des banques. Dans les situations les plus graves, cela peut même conduire à l'insolvabilité de la banque. Ainsi, le risque de crédit est inévitable et intrinsèquement lié aux activités de crédit. Bien que des bénéfices plus élevés incitent à prendre davantage de risque, cela augmente également le risque de pertes lié aux prêts. De ce fait, il est clair que l'augmentation du taux de prêts non-performants exerce une influence négative sur la performance financière des banques en Tunisie.

Ces résultats corroborent les conclusions des travaux de Trujillo-Ponce (2013), Ayaydin et Karakaya (2014), Lee et al (2015), Zhang et al (2016), Chen et al (2018), Partovi et Matousek (2019), Lafuente et al (2019), Huong et al (2021) et Yahaya et al (2022), qui stipulent que plus le risque de crédit est élevé, plus la performance des banques se dégrade.

Considérons maintenant la taille de la banque, nous constatons que cette variable a un impact significatif sur la performance des institutions bancaires. Pour les banques tunisiennes cotées que nous avons étudiées, nous remarquons un coefficient négatif, ce qui indique qu'une augmentation de la taille de la banque engendre une diminution de la marge nette d'intérêt, dès lors notre quatrième hypothèse est rejetée.

Nos conclusions trouvent leur explication dans le fait que plus une banque est grande, plus sa gestion peut devenir complexe, ce qui peut entraîner des coûts opérationnels plus élevés. Cette complexité découle de la nécessité de gérer un volume plus important d'actifs et de passifs. Cette situation peut avoir un impact sur la rentabilité des banques, car des coûts opérationnels plus élevés réduisent leurs bénéfices nets. Ces résultats appuient les conclusions antérieures de Naceur (2003), Berger et Di Patti (2006), Stiroh et Rumble (2006), Kasman et al (2010), Dietrich et Wanzenried (2011) ainsi qu'Aladwan (2015), qui ont tous démontré l'influence négative de la taille de la banque sur leur rentabilité.

Pour le ratio des capitaux propres par rapport au total des actifs, les résultats empiriques nous révèlent que cette variable a un effet significativement positif au seuil de 1%. Cela suggère que lorsque les banques tunisiennes maintiennent des niveaux de capitaux propres plus élevés par rapport à leurs actifs, leurs performances s'améliorent, dès lors notre cinquième hypothèse est validée. Cette conclusion peut être interprétée par le fait que, l'augmentation des capitaux propres d'une banque réduit son niveau d'exposition au risque de faillite. Ainsi, les banques solidement capitalisées ont la possibilité d'investir dans des actifs risqués dans le but d'améliorer leurs rendements, ce qui contribue également à augmenter la marge nette d'intérêt.

En outre, un ratio élevé de capitaux propres dénote la solidité financière d'une banque, renforçant ainsi la confiance des investisseurs. Grâce à cette confiance accrue, les banques peuvent bénéficier de coûts de financement réduits, ce qui leur permet d'emprunter des fonds à des taux d'intérêt plus avantageux. Cette situation leur permet ensuite d'accorder des prêts à des taux plus élevés, entraînant ainsi une augmentation de leurs marges nettes d'intérêts et par conséquent, leurs performances.

Ces résultats soutiennent les conclusions tirées par Bourke (1989), Berger (1995), Demirgüç-Kunt et Huizinga (1999), Pasiouras et Kosmidou (2007), Ben Naceur et Goaid (2008), Kosmidou (2008), Kawshala et Panditharathna (2017), Kohlscheen et al (2018) et Chen et al (2018), qui ont prouvé l'effet positif de la capitalisation sur la performance des institutions bancaires.

Passons à la variable concentration du marché mesuré par l'Indice Herfindahl-Hirschman, le coefficient lié à cette variable est significativement positif au seuil de 1%. En d'autres termes, la concentration bancaire affecte positivement et de manière significative la marge nette d'intérêt. Ces résultats confirment notre hypothèse H6 et sont en cohérence avec les conclusions de l'étude précédente menée par Hakimi et Zaghoudi (2017).

En effet, nous constatons que la concentration bancaire conduit à une amélioration de la performance des banques tunisiennes, suggérant qu'un système bancaire concentré renforce la stabilité financière. Cette concentration en créant un environnement financier plus stable, a le potentiel d'accroître la confiance des investisseurs et des déposants. Cette confiance accrue peut à son tour se traduire par des marges nettes d'intérêts plus élevées, contribuant ainsi à l'amélioration des résultats financiers des banques.

En ce qui concerne, la masse monétaire, les résultats indiquent que le coefficient associé à cette variable est positif et statistiquement significatif au seuil de 1%. L'estimation par la méthode MCG suggère que lorsque la masse monétaire augmente, la performance financière des banques tunisiennes s'améliore, alors notre septième hypothèse est vérifiée. Ce résultat corrobore avec les résultats d'Al-Qudah et Jaradat (2013) ainsi que celles d'Onyekwelu (2022), qui affirment que la performance des banques est positivement influencée par la masse monétaire.

En effet, l'augmentation de la masse monétaire incite les ménages et les entreprises à accroître leurs dépenses et à investir davantage. Les banques, en tant qu'acteurs clés dans ce processus, jouent un rôle essentiel en finançant ces activités par le biais de prêts, ce qui se traduit par une augmentation de leurs revenus d'intérêts, contribuant ainsi à l'amélioration de leur performance financière.

Nous remarquons que la croissance économique n'a pas d'impact significatif sur la performance des banques tunisiennes examinées, ceci contredit les conclusions d'études antérieures menées par Ehekoba et al (2018), Lawal et al (2018), Panigrahi et al (2019) et Qureshi et al (2019), mais soutient les conclusions de Hakimi et Zaghoudi (2017). Nous rejetons donc la huitième hypothèse, laquelle postule un effet positif de la croissance économique sur la performance bancaire. Nous parvenons à la conclusion que la situation économique générale n'a pas d'incidence sur la performance des banques en Tunisie. Cette constatation peut être attribuée au fait que les variables propres à chaque banque intègrent déjà en partie l'effet de la conjoncture économique sur la rentabilité et, par conséquent, sur la performance.

Concernant la crise des subprimes, nous constatons que cette variable externe n'exerce aucune influence significative sur notre variable principale. Cela découle du fait que la taille relativement limitée du marché tunisien et sa stabilité relative ont pu atténuer la vulnérabilité aux chocs mondiaux.

Enfin, les résultats obtenus pour la variable révolution tunisienne indiquent un impact non significatif sur la performance des banques tunisiennes. Ainsi, notre dixième hypothèse est rejetée.

### Conclusion et Recommandations

Les activités bancaires reposent sur la liquidité, qui est donc essentielle à la survie des banques. En raison du rôle fondamental de la liquidité dans ce secteur, une attention particulière a été accordée au risque de liquidité.

L'objectif de cet article est d'analyser l'impact du risque de liquidité sur la performance des banques. Pour ce faire, nous avons examiné un échantillon de 10 banques tunisiennes sur la période allant de 2003 à 2022. La méthode économétrique adoptée est l'analyse des données de panel, en particulier le modèle à effets aléatoires. Les résultats empiriques révèlent que le risque de liquidité, exprimé par le ratio crédits/dépôts, exerce un impact significativement positif sur la performance financière, évaluée à travers la marge nette d'intérêt. Ce constat appuie l'idée selon laquelle la banque vise à maximiser ses revenus d'intérêts en accordant des crédits à des taux élevés et à haut risque, entraînant ainsi une augmentation du ratio LTD.

Par ailleurs, il ressort que la performance financière des banques tunisiennes est positivement influencée par leur capitalisation et la concentration du marché bancaire, tandis qu'elle est affectée négativement par le risque de crédit et la taille de la banque. En ce qui concerne la croissance économique, la crise des subprimes et la révolution tunisienne, les résultats de l'étude indiquent que ces trois variables n'ont pas d'impact significatif sur la performance financière des banques tunisiennes.

Ces résultats ont des implications politiques importantes, soulignant la nécessité pour le gouvernement, les institutions bancaires et les décideurs politiques de se concentrer sur la gestion du risque de liquidité, car ce dernier est un facteur clé qui influence de manière significative la performance du secteur bancaire. Ainsi, il est recommandé que les banques tunisiennes mettent en place des politiques et des pratiques solides, notamment la diversification des sources de financement, la surveillance régulière des indicateurs de liquidité et le développement de plans de gestion de crise pour faire face aux situations de stress financier.

## Références Bibliographiques

- Abdelaziz, H., Rim, B., et Helmi, H., (2022), « The Interactional Relationships Between Credit Risk, Liquidity Risk and Bank Profitability in MENA Region ». *Global Business Review*, 23(3), pp. 561-583.
- Alim, W., Ali, A., et Metla, M.R., (2021), « The Effect of Liquidity Risk Management on Financial Performance of Commercial Banks in Pakistan ». *Journal of Applied Economics and Business*, 9(4), pp. 109-128.
- Al-Qudah, A.M., et Jaradat, M.A., (2013), « The Impact of Macroeconomic Variables and Banks Characteristics on Jordanian Islamic Banks Profitability : Empirical Evidence ». *International Business Research*, 6(10), pp. 153-162.
- Alzorqan, S., (2014), « Bank Liquidity Risk and Performance : An Empirical Study of the Banking System in Jordan ». *Research Journal of Finance and Accounting*, 5(12), pp. 155-164.
- Arif, A., et Nauman Anees, A., (2012), « Liquidity Risk and Performance of Banking System ». *Journal of Financial Regulation and Compliance*, 20(2), pp. 182-195.
- Ayaydin, H., et Karakaya, A., (2014), « The Effect of Bank Capital on Profitability and Risk in Turkish Banking ». *International Journal of Business and Social Science*, 5(1), pp. 252-271.
- Bourke, P., (1989), « Concentration and Other Determinants of Bank Profitability in Europe, North America and Australia ». *Journal of Banking & Finance*, 13(1), pp. 65-79.
- Chen, W.D., Chen, Y., et Huang, S.C., (2021), « Liquidity Risk and Bank Performance During Financial Crises ». *Journal of Financial Stability*, 56, pp. 1-23.
- Chen, Y.K., Shen, C.H., Kao, L., et Yeh, C.Y., (2018), « Bank Liquidity Risk and Performance ». *Review of Pacific Basin Financial Markets and Policies*, 21(01), pp. 1-40.
- Chowdhury, A.M.H., Chowdhury, A.S.M.M.H., et Siddiqua, A., (2016), « Relationship Between Liquidity Risk and Net Interest Margin of Conventional Banks in Bangladesh ». *Asian Business Review*, 6(3), pp. 175-178.
- Chowdhury, M.M., et Zaman, S., (2018), « Effect of Liquidity Risk on Performance of Islamic Banks in Bangladesh ». *Journal of Economics and Finance*, 9(4), pp. 01-09.
- Ebenezer, O.O., Islam, M.A., Yusoff, W.S., et Rahman, S., (2019), « The Effects of Liquidity Risk and Interest-Rate Risk on Profitability and Firm Value Among Banks in ASEAN-5 Countries ». *Journal of Reviews on Global Economics*, 8, pp. 337-349.
- Ferrouhi, E.M., (2014), « Bank Liquidity and Financial Performance : Evidence From Moroccan Banking Industry ». *Verslas : Teorija Ir Praktika*, 15(4), pp. 351-361.
- Hacini, I., Bouloufad, A., et Dahou, K., (2021), « The Impact of Liquidity Risk Management on the Financial Performance of Saudi Arabian Banks ». *Emerging Markets Journal*, 11(1), pp. 67-75.
- Hakimi, A., et Zaghdoudi, K., (2017), « Liquidity Risk and Bank Performance : An Empirical Test for Tunisian Banks ». *Business and Economic Research*, 7(1), pp. 46-57.
- Huong, T.T.X., Nga, T.T.T., et Oanh, T.T.K., (2021), « Liquidity Risk and Bank Performance in Southeast Asian Countries : a Dynamic Panel Approach ». *Quantitative Finance and Economics*, 5(1), pp. 111-133.
- Kalimashi, A., Ahmeti, S., et Aliu, M., (2022), « The Relationship Between Liquidity Risk Management and Commercial Bank Performance : Evidence From the Western Balkans ». *International Journal of Applied Economics, Finance and Accounting*, 14(2), pp. 129-136.
- Kawshala, H., et Panditharathna, K., (2017), « The Factors Effecting on Bank Profitability ». *International Journal of Scientific and Research Publications*, 7(2), pp. 212-216.
- Khalid, M.S., Rashed, M., et Hossain, A., (2019), « The Impact of Liquidity Risk on Banking Performance : Evidence From the Emerging Market ». *Global Journal of Management and Business Research*, 19(4), pp. 47-52.
- Lee, J.Y., Growe, G., DeBruine, M., et Cha, I., (2015), « Measuring the Impact of the 2007-2009 Financial Crisis on the Performance and Profitability of US Regional Banks ». In *Advances in Management Accounting*, 25, pp. 181-206.

- Ly, K.C., (2015), « Liquidity Risk, Regulation and Bank Performance : Evidence from European banks ». *Global Economy and Finance Journal*, 8(1), pp. 11-33.
- Madhuwanthi, R.M.R., et Morawakage, P.S., (2019), « Impact of Liquidity Risk on the Performances of Sri Lankan Commercial Banks ». *Sri Lanka Journal of Social Sciences*, 42(1), pp. 53-64.
- Marozva, G., (2015), « Liquidity and Bank Performance ». *International Business & Economics Research Journal*, 14(3), pp. 453-562.
- Muriithi, J.G., et Waweru, K.M., (2017), « Liquidity Risk and Financial Performance of Commercial Banks in Kenya ». *International Journal of Economics and Finance*, 9(3), pp. 256-265.
- Ndoka, S., Islami, M., et Shima, J., (2017), « The Impact of Liquidity Risk Management on the Performance of Albanian Commercial Banks During the Period 2005-2015 ». *International Journal of Social Sciences and Education Research*, 3(1), pp. 70-76.
- Partovi, E., et Matousek, R., (2019), « Bank Efficiency and Non-Performing Loans : Evidence From Turkey ». *Research in International Business and Finance*, 48, pp. 287-309.
- Pasiouras, F., et Kosmidou, K., (2007), « Factors Influencing the Profitability of Domestic and Foreign Commercial Banks in the European Union ». *Research in International Business and Finance*, 21(2), pp. 222-237.
- Shen, C.H., Chen, Y.K., Kao, L.F., et Yeh, C.Y., (2009), « Bank Liquidity Risk and Performance ». 17th Conference on the Theories and Practices of Securities and Financial Markets, Hsi-Tze Bay, Kaohsiung, Taiwan.
- Tabari, N.A.Y., Ahmadi, M., et Emami, M., (2013), « The Effect of Liquidity Risk on the Performance of Commercial Banks ». *International Research Journal of Applied and Basic Sciences*, 4(6), pp. 1624-1631.
- Yahaya, A., Mahat, F., Yahya, M.H., et Matemilola, B.T., (2022), « Liquidity Risk and Bank Financial Performance : An Application of System GMM Approach ». *Journal of Financial Regulation and Compliance*, 30(3), pp. 312-334.
- Zhang, D., Cai, J., Dickinson, D.G., et Kutan, A.M., (2016), « Non-Performing Loans, Moral Hazard and Regulation of the Chinese Commercial Banking System ». *Journal of Banking & Finance*, 63, pp. 48-60.

## Annexes

## Annexe 1 : Résumé des variables indépendantes

Variables explicatives	Mesures	Signe attendu
Risque de liquidité (LIQR)	$LIQR_{it} = \frac{Total\ Crédits}{Total\ Dépôts}$	(-)/(+)
Risque de crédit (CRDR)	$NPL_{it} = \frac{Créances\ classées\ (Classe\ 2,\ 3\ et\ 4)}{Total\ engagements}$	(-)
Taille de la banque (SIZE)	$SIZE_{it} = \ln(Total\ Actifs_{it})$	(+)
Ratio de capital (CAP)	$CAP_{it} = \frac{Capitaux\ propres}{Total\ Actifs}$	(+)
Concentration du marché (IHH)	$IHH_t = \sum_{i=1}^{10} (Part\ de\ marché\ du\ total\ des\ actifs_i)^2$	(+)
Crise financière internationale (CRISIS)	Une variable muette captant l'effet de la crise des subprimes, qui prend la valeur 1 durant la période 2007- 2009, sinon 0.	(-)
Révolution tunisienne (REVOL)	Une variable dummy qui signale la période de la révolution tunisienne de 2011, prenant la valeur 1 de 2011 à 2014, et 0 en dehors de cette période.	(-)
Masse monétaire (M2)	$M2_t = \ln(Masse\ monétaire\ au\ sens\ de\ M2_t)$	(+)
Croissance économique (GPIB)	$GPIB = \text{taux de croissance du PIB}$ $Taux\ de\ croissance\ (\%) = \frac{PIB_t - PIB_{t-1}}{PIB_{t-1}} \times 100$	(+)

Source : Elaboré par l'auteure

## Annexe 2 : Matrice de corrélation

	MNI	LIQR	CRDR	SIZE	CAP	IHH	CRISIS	REVOL	M2	GPIB
MNI	1.0000									
LIQR	0.2910	1.0000								
CRDR	-0.2643	0.1143	1.0000							
SIZE	-0.1257	0.2064	-0.1730	1.0000						
CAP	0.3501	0.2399	-0.3275	-0.1256	1.0000					
IHH	0.1362	-0.0004	0.1686	-0.1288	0.2265	1.0000				
CRISIS	-0.0017	-0.2923	0.0378	-0.2478	-0.0799	0.1041	1.0000			
REVOL	-0.0437	-0.0285	-0.0831	0.0370	-0.2099	-0.5397	-0.2100	1.0000		
M2	0.0992	0.2540	-0.3789	0.7787	0.0671	-0.1519	-0.3041	-0.0621	1.0000	
GPIB	-0.0636	-0.1628	0.2120	-0.4007	-0.0686	0.1924	0.2745	-0.0967	-0.5183	1.0000

Source : Calcul de l'auteure à partir du logiciel Stata 16

**Annexe 3 : Résultat du test d'homogénéité**

<b>Statistique de Fisher F(9,190)</b>	9.09
<b>P-value</b>	0.0000

*Source : Calcul de l'auteure à partir du logiciel Stata 16*

**Annexe 4 : Résultat du test d'Hausman**

Test de chi2	P-value	Modèle de spécification	Estimation
6.04	0.7363	Modèle à effet aléatoire	MCG

*Source : Calcul de l'auteure à partir du logiciel Stata 16*

**Annexe 5 : Résultat du test d'hétéroscédasticité**

<b>Chi2(1)</b>	0.62
<b>P-value</b>	0.4307

*Source : Calcul de l'auteure à partir du logiciel Stata 16*


**Annexe 6 : Résultat du test d'autocorrélation**

<b>F(1,9)</b>	110.019
<b>P-value</b>	0.0000

*Source : Calcul de l'auteure à partir du logiciel Stata 16*

## L'impact du système de contrôle de gestion sur la performance globale de la banque (Cas de l'ATB)

Ameni TOUFFEHI  
Arab Tunisian Bank-ATB



### Résumé

Notre recherche vise à approfondir la compréhension de l'impact du système de contrôle de gestion sur la performance globale de la banque en identifiant les facteurs qui y contribuent. Une enquête quantitative a été menée auprès de 100 participants, comprenant des directeurs et des chefs d'agence de l'Arab Tunisian Bank. Les résultats obtenus à travers l'analyse des équations structurelles sous AMOS apportent des éclairages significatifs. Ils révèlent une influence positive marquée de la composante informelle du système de contrôle de gestion sur la performance globale de la banque. Cette constatation souligne l'importance des mécanismes informels de gestion dans la dynamique du succès global de l'institution. De plus, les résultats mettent en lumière le rôle crucial du partage des connaissances et de l'apprentissage organisationnel en tant que moteurs supplémentaires de cette performance.

Ces conclusions suggèrent que la performance d'une banque ne dépend pas uniquement de structures formelles de contrôle, mais également des interactions informelles et des processus d'apprentissage au sein de l'organisation. En développant une compréhension approfondie de ces dynamiques, notre recherche offre des perspectives précieuses pour guider les pratiques de gestion vers des approches plus holistiques, favorables à une performance globale durable.

**Mots clés :** Système de Contrôle de gestion, performance globale, contrôle de gestion informelle, apprentissage organisationnel, partage des connaissances, modélisation par équations structurelles.

### Introduction

Les banques, en tant que pierre angulaire de toute économie, assument un rôle fondamental en facilitant la rencontre entre les fournisseurs et les demandeurs de capitaux. Bien que ce rôle ait connu diverses évolutions, l'activité bancaire demeure toujours à la base de tout mécanisme financier. Ainsi, la position centrale occupée par les banques dans l'économie et le risque potentiel de les voir en difficulté ne peuvent laisser les pouvoirs publics indifférents.

Pour la majorité des banques, le contrôle de gestion occupe désormais une position cruciale. Il a évolué de sa fonction initiale de second plan pour devenir un avantage concurrentiel pour les établissements qui mettent en place des méthodes de calcul de rentabilité, de suivi des performances, et une structuration en centres de responsabilité, voire en lignes métier.

Il n'est plus possible de considérer comme acquis que toute activité génère automatiquement des revenus bénéfiques. Le seul système de contrôle de gestion efficace qui permet aux dirigeants de prendre des décisions éclairées et de piloter des portefeuilles d'activités de plus en plus complexes est celui qui est performant. Les gestionnaires et les opérateurs, quel que soit leur niveau hiérarchique, sont constamment sollicités pour améliorer, rétablir ou maintenir des niveaux acceptables de performance économique. À cette fin, une information pertinente, rapide et de qualité est indispensable, et c'est précisément le rôle du contrôle de gestion de la fournir.



Le contrôle de gestion est un outil d'exécution de la stratégie, il la traduit en plans d'action et résultats opérationnels. Au cœur des préoccupations stratégiques des institutions bancaires réside la question cruciale de la performance globale, une équation complexe influencée par divers facteurs internes et externes. Parmi ces éléments, le système de contrôle de gestion émerge comme un levier potentiel pour optimiser les performances financières et non financières.

Au-delà de la reconnaissance de l'importance du contrôle de gestion en tant que mécanisme de surveillance et de régulation, il devient impératif d'analyser comment ces dispositifs influent sur les performances de la banque dans son ensemble.

## **1. Revue de la littérature**

### **1.1. Concepts de la recherche**

#### **1.1.1. Notion du contrôle de gestion**

##### **1.1.1.1. Le système de contrôle de gestion formel**

Le contrôle de gestion, défini par Simons (1995) comme l'utilisation de routines et de procédures formelles pour ajuster les tendances organisationnelles, et par Malmi et Brown (2008) comme un ensemble de systèmes visant à orienter le comportement des employés, est crucial dans le secteur bancaire pour évaluer la rentabilité, élaborer des rapports et des budgets, et assurer une gestion efficace et une performance financière solide. Les contrôleurs de gestion bancaire jouent un rôle clé dans ce processus, tandis que les tableaux de bord prospectifs fournissent une vue synthétique des performances de la banque aux directions générales.

##### **1.1.1.2. Le système de contrôle de gestion informel**

Le contrôle informel dans une organisation repose sur les échanges, les interactions et les liens relationnels qui se forment lors de la résolution des problèmes. Ces processus favorisent la cohésion et la cohérence des comportements organisationnels, tout en étant influencés par des aspects culturels et professionnels (Jaworski et al (1993) et Cravens et al (2004)). Selon Guibert et Dupuy (1997), cette cohésion est vitale pour assurer les performances nécessaires à la survie et à la croissance de l'organisation. Pour maintenir cette cohésion, la communication efficace, les relations interpersonnelles et la culture organisationnelle sont essentielles.

##### **1.1.1.3. Le partage des connaissances**

Le processus de transfert des connaissances au sein d'une organisation, selon Alavi et Leidner (2001), implique l'échange de connaissances entre les membres et les parties prenantes via différents moyens de communication. Dans le secteur bancaire, ce partage de connaissances peut améliorer la performance organisationnelle en permettant une meilleure gestion des risques, une qualité de service accrue, une réduction des coûts et une prise de décision plus éclairée (Lee et Choi, 2003). Les banques peuvent favoriser ce partage en mettant en place des communautés de pratique entre les employés, ce qui contribue à améliorer la performance globale de l'organisation.

##### **1.1.1.4. L'apprentissage organisationnel**

L'apprentissage organisationnel se réfère à l'introduction de nouvelles connaissances susceptibles de provoquer des changements significatifs dans le comportement d'une organisation (Messaoudi et al (2019)). Ces évolutions de comportement ne se matérialiseront que si l'entreprise est disposée à instaurer, acquérir, transférer et intégrer une nouvelle vision fondée sur les connaissances nouvellement acquises. Cela vise à atteindre des performances supérieures à celles de ses concurrents (Jerez Gomez et al (2005)).

Au niveau de la banque, l'apprentissage organisationnel est essentiel pour maintenir la compétitivité, la conformité réglementaire, la qualité des services et la gestion efficace des risques. Il repose sur la collecte, le partage et l'application de connaissances pour s'adapter aux changements du marché financier et pour répondre aux besoins et attentes des clients.

### 1.1.1.5. La performance globale

Kaplan et Norton (1998) ont développé un cadre de mesure de la performance globale qui intègre des indicateurs financiers et non financiers. Ils soutiennent que les indicateurs financiers seuls ne fournissent pas une image complète de la santé d'une entreprise, car ils se concentrent trop sur les résultats à court terme. Les indicateurs non financiers, en revanche, permettent de mesurer les performances à long terme, telles que la satisfaction des clients, l'efficacité opérationnelle ou la gestion des risques.

## 1.2. Les hypothèses de recherche

### 1.2.1. Les effets du contrôle de gestion formel sur le partage des connaissances

Les systèmes de contrôle de gestion formalisés sont des outils essentiels pour améliorer le partage des connaissances au sein des organisations. L'étude d'Aubert et al. (2004) a démontré que ces systèmes permettent de repérer les connaissances pertinentes, de les diffuser efficacement et d'en garantir la qualité. De plus, la recherche de Xu et al. (2012) a révélé que les systèmes de contrôle de gestion formalisés peuvent encourager les employés à partager leurs connaissances, ce qui peut conduire à la création de nouvelles connaissances.

En s'appuyant sur la définition relative au partage des connaissances et en se basant sur la revue de littérature nous proposons l'hypothèse suivante :

**H1a :** Le système de contrôle de gestion formel présente un effet positif sur le partage des connaissances.

### 1.2.2. Les effets du contrôle de gestion formel sur l'apprentissage organisationnel

Traditionnellement, le contrôle de gestion et l'apprentissage organisationnel étaient considérés comme des concepts opposés. Ils étaient rarement étudiés ensemble dans le domaine de la gestion. Cependant, des recherches récentes ont montré que le contrôle de gestion peut contribuer positivement au développement de l'apprentissage organisationnel. (El Haouary et Skouri (2019)).

Kloot (1997) affirme que les définitions des systèmes de contrôle et de l'apprentissage organisationnel ont des objectifs similaires puisqu'elles examinent toutes deux la façon dont une organisation se développe et s'ajuste à son environnement.

Par conséquent, les systèmes de contrôle se présentent comme l'un des éléments clés qui encouragent les processus d'apprentissage organisationnel, d'où l'hypothèse suivante :

**H1b :** Le système de contrôle de gestion formel présente un effet positif sur l'apprentissage organisationnel.

### 1.2.3. Les effets du contrôle de gestion informel sur l'apprentissage organisationnel

Le contrôle de gestion informel peut également encourager l'apprentissage organisationnel en facilitant le partage de connaissances entre les employés. En créant un cadre moins structuré et en encourageant des interactions plus libres, il permet aux membres de l'organisation d'échanger des informations, des idées, et de tirer des enseignements mutuels. Cela favorise l'acquisition et la diffusion des connaissances au sein de l'entreprise, contribuant ainsi à l'amélioration de ses performances et à son adaptation aux évolutions de l'environnement (Jaworski et al (1993) et Cravens et al (2004)). Sur cette base nous formulons l'hypothèse suivante :

**H2a** : Le système de contrôle de gestion informel présente un effet positif sur l'apprentissage organisationnel.

#### 1.2.4. Les effets du contrôle de gestion informel sur le partage des connaissances

Une revue de littérature sur la relation contrôle de gestion informel et partage des connaissances, nous a permis de relever que de nombreux auteurs (Guibert et Dupuy (1997), Chatelain-Ponroy (2010) et Bouquin (2005)) s'accordent sur l'influence de contrôle informel sur le partage des connaissances.

Le contrôle de gestion informel peut jouer un rôle significatif dans la promotion du partage de connaissances entre les employés. En favorisant une atmosphère de travail propice à des échanges plus informels, tels que des discussions en dehors des cadres formels, des interactions plus libres et des relations interpersonnelles renforcées, ce type de contrôle peut encourager une communication plus ouverte et spontanée.

Conformément aux conclusions ci-dessus, l'hypothèse suivante est proposée :

**H2b** : Le système de contrôle de gestion informel présente un effet positif sur le partage des connaissances.

#### 1.2.5. Les effets du partage des connaissances sur la performance globale

Le partage des connaissances peut stimuler l'innovation. En partageant leurs connaissances, les employés peuvent générer de nouvelles idées et perspectives. Cela peut conduire au développement de nouveaux produits, services ou processus qui peuvent générer des revenus et améliorer la rentabilité (Hansen et al (2005)).

D'après Alavi et Leidner (2001), le partage des connaissances peut renforcer la collaboration et la communication, le partage des connaissances peut aider les banques à mieux servir leurs clients et à améliorer l'efficacité des opérations. Cela peut conduire à une augmentation de la satisfaction des clients, à une réduction des coûts et à une amélioration de la productivité.

Sur la base des observations de recherche précédentes, l'hypothèse suivante a été formulée :

**H3** : Le partage des connaissances présente un effet positif sur la performance globale.

#### 1.2.6. Les effets de l'apprentissage organisationnel sur la performance globale

Selon Dickson (1996), l'apprentissage organisationnel permet aux entreprises de rester compétitives et de gérer efficacement les perturbations inattendues. Des études, comme celles de Baker et Sinkula (1999), ont montré que cet apprentissage a un impact direct sur les performances globales des entreprises. De plus, Bontis et al. (2002) et Darroch et McNaughton (2002) ont confirmé que l'apprentissage organisationnel améliore significativement la performance organisationnelle. Cette hypothèse suivante est avancée :

**H4** : L'apprentissage organisationnel présente un effet positif sur la performance globale.

## 2. METHODOLOGIE DE LA RECHERCHE

### 2.1. La posture épistémologique et la démarche adoptée

#### 2.1.1. La posture épistémologique

À la lumière de la problématique qu'elle tente de mettre en avant et dans le but de tester le modèle de recherche ainsi que les hypothèses qui en découlent, cette étude peut être intégrée dans une approche positiviste avec un mode de raisonnement hypothético-déductif. Notre objectif est d'expliquer et de comprendre la relation causale entre le système de contrôle de gestion (variable indépendante) et la

performance globale (variable dépendante), en passant par les variables médiatrices que sont le partage des connaissances et l'apprentissage organisationnel.

En effet, notre objectif est de réaliser une étude visant à apporter des éléments de réponse à la question suivante : **Dans quelle mesure le système de contrôle de gestion contribue-t-il réellement à la performance globale de la banque ? »**

### 2.1.2. La démarche adoptée

Pour mener à bien notre recherche, nous allons opter pour une approche quantitative, qui est couramment associée à une perspective positiviste et à un raisonnement hypothético-déductif. Cette démarche englobe la collecte, l'analyse et la présentation des données de manière quantitative, en se basant sur la méthode des équations structurelles. Elle offre la possibilité d'établir des liens entre diverses variables et de vérifier la validité des hypothèses émises.

## 2.2. Echantillon et données

### 2.2.1. Outils de collecte de données

Le questionnaire a été créé sur Google Forms et diffusé par mail à un échantillon de cadres, directeurs et chef d'agence. Les résultats obtenus reflètent les avis des répondants. Le questionnaire couvre les thèmes suivants :

- Les pratiques de contrôle de gestion au niveau de l'ATB.
- Le partage de connaissances.
- L'apprentissage organisationnel.
- La performance non financière.
- La performance financière.

### 2.2.2. Présentation de l'échantillon

Nous avons recueilli des données auprès d'un échantillon de 100 individus, initialement composé de 46 individus, en appliquant la méthode du "bootstrapping". Cette méthode statistique implique la création de nombreux échantillons simulés en ré-échantillonnant un ensemble de données. Ce processus nous permet de calculer les écarts types et de réaliser des tests d'hypothèses.

Notre échantillon de départ se compose de 14 chefs d'agence, 11 directeurs de zone, 8 directeurs centraux et 13 responsables.

La méthode d'échantillonnage choisie est de nature quantitative, se manifestant à travers l'utilisation du questionnaire, avec la méthode de collecte de données précédemment évoquée.

## 2.3. Echelle de mesure des variables et présentation du modèle

Nous avons opté pour l'utilisation d'échelles préexistantes pour chacune des variables. Un ensemble d'échelles de Likert à sept points, allant de "pas du tout d'accord" à "tout à fait d'accord," (de 1= pas du tout d'accord, 2= pas d'accord, 3= en désaccord, 4= relativement d'accord, 5= relativement d'accord, 6= d'accord, 7= tout à fait d'accord) a été employé pour chaque variable du modèle à l'étude.

## 2.4. Le modèle

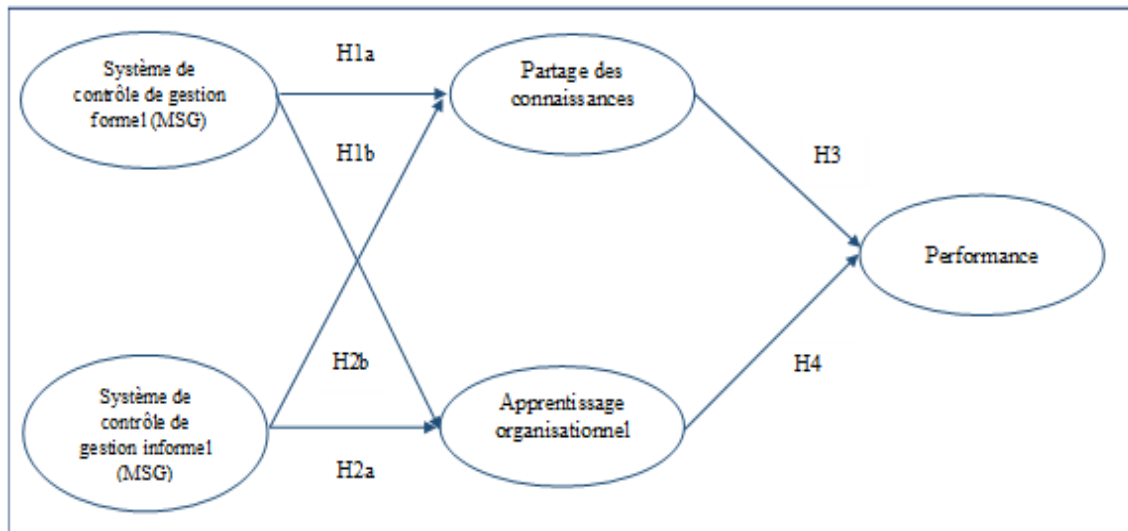
Pour conduire efficacement notre recherche, nous allons adopter la modélisation par équations structurelles (MES). Cette méthode d'analyse vise à évaluer les relations causales entre différentes variables.

Notre démarche de recherche comprend deux phases d'analyse distinctes : une analyse exploratoire (utilisant SPSS) pour identifier les relations potentielles entre les variables, et une analyse

de confirmation (employant la méthode des équations structurelles avec AMOS) pour évaluer la validité de ces relations.

Suite à la revue des études et de la littérature existante, nous avons formulé un modèle conceptuel, présenté dans la figure 1 ci-dessous, qui sera soumis à des tests.

**Figure 1 : Modèle conceptuel**



Source : Elaboré par l'auteure

### 3. Interprétation et discussion des résultats

#### 3.1. Interprétation des résultats

Notre étude repose sur l'application de deux méthodes d'analyse, à savoir l'analyse exploratoire (utilisant SPSS) et l'analyse de confirmation (employant la méthode des équations structurelles avec AMOS).

##### 3.1.1. Résultat de l'analyse descriptive

L'analyse descriptive est indispensable pour comprendre les données. Le tableau présente les résultats d'un test de moyenne et d'écart-type pour un échantillon de 100 individus. Les données ont été obtenues en utilisant la méthode de bootstrapping, qui consiste à ré-échantillonner les données pour créer de nombreux échantillons simulés.

La moyenne est proche du centre de l'intervalle de confiance, ce qui suggère que les données sont relativement concentrées autour de la moyenne. L'écart-type est également relativement faible variant entre 1.3 et 1.4, ce qui suggère que les valeurs des données sont relativement proches les unes des autres. (Annexes 2).

Ces résultats suggèrent que le questionnaire est valide et qu'il peut être utilisé pour l'analyse factorielle.

##### 3.1.2. Résultats de l'analyse factorielle exploratoire

###### 3.1.2.1. Adéquation de l'échantillon

- Tests KMO et Bartlett :

Les résultats ci-dessous montrent que le test KMO montre que chi-deux (chi square) est très significatif ( $KMO > 0,6$ ) et que les données pourront être utilisées dans la suite des analyses.

**Tableau 1 : Test KMO et Bartlett**

<b>Kaiser-Meyer-Olkin Measure of Sampling Adequacy</b>		<b>0.845</b>
<b>Bartlett's Test of Sphericity</b>	<b>Approx. Chi-Square</b>	<b>4960.364</b>
	<b>df</b>	<b>861</b>
	<b>Sig.</b>	<b>0.000</b>

Source : outputs SPSS

- Analyse en composantes principales

L'analyse en composantes principales tel que décrite dans le graphique en (annexe 2) permet de retenir seulement 5 facteurs qui expliquent à eux seuls 75.8 % de la variance entre les items, ce qui correspond parfaitement à nos attentes.

L'articulation des données autour des variables latentes est représentée par le tableau des matrices de structure (annexe 3). Les items contribuent fortement à la constitution de leur variable latente, avec des coefficients supérieurs à 0,5. Ces résultats doivent être confirmés par une analyse confirmatoire.

- Test de fiabilité

Pour la variable MSGform, Le tableau ci-dessous est le tableau des statistiques de fiabilité qui fournit la valeur de Cronbach alpha qui dans ce cas est 0.951 ce coefficient est supérieur à 0,7 ce qui signifie que la variable MSGform est considérée comme fiable. En d'autres termes, les questions qui composent la variable MSGform mesurent une même dimension. Les réponses aux différentes questions sont donc cohérentes entre elles.

**Tableau 2 : Tableau des statistiques de fiabilité de la variable MSGform**

<b>Cronbach's Alpha</b>	<b>Cronbach's Alpha Based On Standardized Items</b>	<b>N of Items</b>
<b>0.951</b>	0.951	7

Source : Elaboré par l'auteure à partir des outputs SPSS

**Tableau 3 : Statistiques du Total des indicateurs**

	<i>Scale Mean if Item Deleted</i>	<i>Scale Variance if Item Deleted</i>	<i>Corrected Item-Total Correlation</i>	<i>Squared Multiple Correction</i>	<i>Cronbach's Alpha if Item Deleted</i>
<i>MCGform1</i>	30.1900	56.782	0.841	0.718	<b>0.943</b>
<i>MCGform2</i>	30.2200	56.497	0.810	0.726	<b>0.945</b>
<i>MCGform3</i>	30.2800	56.082	0.824	0.689	<b>0.944</b>
<i>MCGform4</i>	30.1800	52.048	0.913	0.862	<b>0.937</b>
<i>MCGform5</i>	30.1400	58.788	0.776	0.676	<b>0.948</b>
<i>MCGform6</i>	30.0900	55.073	0.869	0.842	<b>0.940</b>

<i>MCGform7</i>	30.1600	55.348	0.809	0.741	0.946
-----------------	---------	--------	-------	-------	-------

Source : Elaboré l'auteure à partir des outputs SPSS

Les scores de "Alpha de Cronbach si l'indicateur est supprimé" pour tous les items sont inférieurs à la valeur alpha de Cronbach de la variable MSGform. En conséquence, tous les items sont jugés significatifs (Annexe 4).

### 3.1.3. Analyse confirmatoire des échelles de mesures

En ce qui concerne la variable MSGform, le tableau de la matrice des composantes révèle une covariance de 0,909, tandis que dans le schéma de covariance, cette valeur est indiquée à 0,85. Cela suggère que l'élément MCGform1 contribue à hauteur de 85% à la formation de la variable MSGform, alors que dans le tableau, nous avons trouvé une contribution de 90%. Le schéma de covariance se révèle plus réaliste que le tableau. En d'autres termes, bien que le tableau indique une covariance de 90%, l'exploration de la covariance entre les items et les différentes variables dans le schéma a donné un résultat plus fidèle à la réalité, le reste étant attribué aux termes d'erreur.

En ce qui concerne la variable "performance", l'élément NOFin1 contribue à hauteur de 75% à la constitution de cette variable, en tenant compte de la covariance de la performance avec chacune des autres variables. La partie non expliquée par cet indicateur est de 25%, et elle est intégrée dans son terme d'erreur (e14). Pour la variable "partage des connaissances", l'élément KowShr6 contribue à hauteur de 85% à la formation de cette variable, en prenant en considération la covariance avec chacune des autres variables. La partie non expliquée par cet indicateur s'élève à 15% et est incorporée dans son terme d'erreur (e33). (Annexe 5)

Trois étapes au mois sont nécessaires pour confirmer la structure des variables latentes :

- Mesures d'ajustement du modèle (Model Fit Measures).
- La validité convergente et la validité discriminante (Model Validity Measures).
- Le biais de la méthode commune de collecte de données (commun method bias).

#### ➤ Mesures d'ajustement du modèle (Model Fit Measures)

**Tableau 4 : Indices des ajustements de modèle**

<i>Paramètres</i>	<i>Valeurs</i>	<i>Interprétation</i>
<i>CMIN/df</i>	2.210	Excellent
<i>CFI</i>	0.95	Acceptable
<i>SRMR</i>	0.089	Acceptable
<i>RMSA</i>	0.06	Acceptable
<i>PClose</i>	0.05	Acceptable

Source : Elaboré par l'auteure à partir des outputs Amos

#### ➤ La validité convergente

**Tableau 5 : Signification et Fiabilité Composée (ρ) par construit**

<b>Composite Reliability</b>
------------------------------

<b>Performance</b>	0.970
<b>Système de contrôle de gestion informel</b>	0.937
<b>Système de contrôle de gestion formel</b>	0.952
<b>Partage des connaissances</b>	0.927
<b>Apprentissage organisationnel</b>	0.973

Source : Elaboré l'auteure à partir des outputs SPSS

Selon ce test, tous les items contribuent à la variable, car le coefficient de corrélation (CR) est supérieur à 0,7 pour chacun d'entre eux.

➤ **La validité discriminante (Model Validity Measures)**

Tableau 6 : La validité discriminante mesurée par la variance moyenne extraite (AVE) au carré

	<i>CR</i>	<i>AVE</i>	<i>MSV</i>	<i>MaxR(H)</i>	<i>Perform</i>	<i>MCSinf</i>	<i>MCSform</i>	<i>KowMgt</i>	<i>Lern</i>
<b>Perform</b>	0.970	0.701	0.329	0.975	<b>0.837</b>				
<b>MCSinf</b>	0.937	0.599	0.329	0.939	0.574***	<b>0.774</b>			
<b>MCSform</b>	0.952	0.738	0.167	0.960	0.409***	0.350**	<b>0.859</b>		
<b>KowMgt</b>	0.927	0.646	0.129	0.933	0.359**	0.086	-0.083	<b>0.804</b>	
<b>Lern</b>	0.973	0.901	0.203	0.976	0.450***	0.271*	0.215*	0.191†	<b>0.949</b>

Validity Concerns: Significance of Correlations: † p < 0.100. \* p < 0.050, \*\* p < 0.010, \*\*\* p < 0.001

Source : Elaboré par l'auteure à partir des outputs SPSS

Les éléments d'un construit contribuent de manière significative à ce construit spécifique, tout en ayant une influence moindre sur les autres construits du modèle. Par conséquent, nous pouvons conclure que les critères nécessaires pour assurer la validité discriminante de tous les construits de notre modèle de recherche sont respectés.

➤ **Le biais de la méthode commune de collecte de données (commun method bias)**

D'après le tableau VTE présenté en annexe 6, le premier facteur explique 37,292 % de la variance totale, ce qui est nettement inférieur à 50 %. Cela indique l'absence de biais commun. En ce qui concerne la variance expliquée par la solution initiale, seuls les cinq premiers facteurs de cette solution ont des valeurs propres supérieures à 1. Ensemble, ils représentent 75,826 % de la variabilité des variables d'origine, ce résultat confirme l'analyse en composantes principales.



**Tableau 7 : Variance totale expliquée**

Component	Initial Eigenvalues			Extraction sums of squared loading			Rotation sums of squared loadings
	Total	% of variance	Cumulative %	Total	% of variance	Cumulative %	Total
1	15.663	37.292	37.292	15.663	37.292	37.292	13.994
2	6.047	14.397	51.690	6.047	14.397	51.690	9.769
3	4.129	9.831	61.520	4.129	9.831	61.520	7.807
4	3.284	7.820	69.341	3.284	7.820	69.341	6.492
5	2.724	6.485	75.826	2.724	6.485	75.826	6.791

Source : Elaboré par l'auteure à partir des outputs SPSS

Les trois étapes de l'analyse ont été examinées et ont été concluantes. Nous pouvons donc passer à l'analyse confirmatoire des relations structurelles de la régression.

### 3.1.4. Analyse Confirmatoire (CFA) du modèle structurel

#### 3.1.4.1.L'estimation des résultats pour les hypothèses des liens isolés

Dans cette étude, nous avons testé un modèle structurel de la relation entre « système de contrôle de gestion », « partage des connaissances », « apprentissage organisationnel », et la performance globale de la banque Les hypothèses testées sont les suivantes :

**Tableau 8 : Tests des hypothèses**

	Estimate	S.E.	C.R.	P	Hypothèses	Décision
KowMgt <--MCSform	-0.121	0.085	-1.413	0.158	H1a	Rejetée
Lern <---MCSform	0.136	0.142	0.958	0.338	H1b	Rejetée
KowMgt <--- MCSinf	0.194	0.096	2.028	0.043	H2a	Acceptée
Lern <--- MCSinf	0.440	0.159	2.768	0.006	H2b	Acceptée
Perform<--- KowMgt	0.473	0.151	3.125	0.002	H3.	Acceptée
Perform<--- Lern	0.496	0.088	5.658	***	H4.	Acceptée

Source : Elaboré par l'auteure à partir des outputs AMOS

Le « système de contrôle de gestion informel » exerce une influence positive et significative sur « le partage des connaissances » et « l'apprentissage organisationnel » (p-value (KowMgt)<0.05) et p-value (Lern<0.05)). Ces deux variables ont également un impact significatif et positif sur « la performance globale », avec p-valeurs inférieures au seuil critique de 5%. En conséquence, nous pouvons conclure à la validité des hypothèses H2a, H2b, H3, et H4.

La variable du système de contrôle de gestion formel démontre un effet positif, bien que non significatif, sur l'apprentissage organisationnel (p-value>0.05). Cependant, la variable "système de

contrôle de gestion formel" présente un effet non seulement non significatif mais aussi négatif, d'où les hypothèses H1a et H1b sont rejetées.

**Tableau 9 : Poids de régression standardisés**

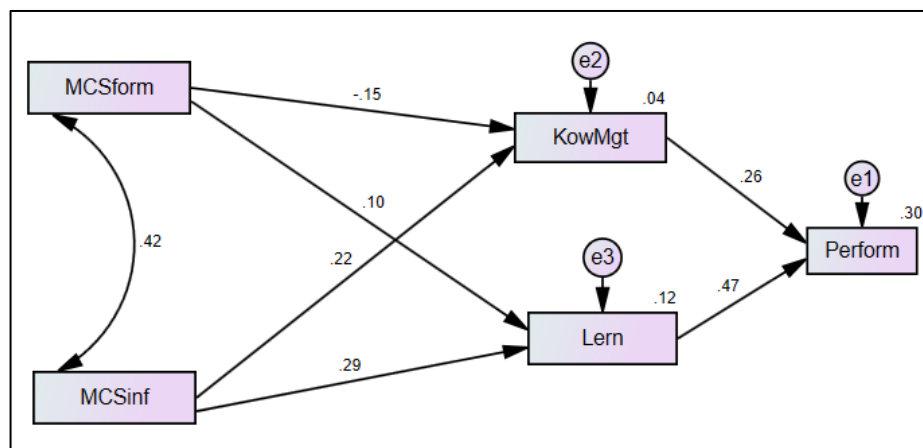
	<i>Estimate</i>
<b>KowMgt &lt;--- MCSform</b>	-.153
<b>Lern &lt;--- MCSform</b>	.100
<b>KowMgt &lt;--- MCSinf</b>	.220
<b>Lern &lt;--- MCSinf</b>	.288
<b>Perform &lt;--- KowMgt</b>	.262
<b>Perform &lt;--- Lern</b>	.475

*Source : Outputs AMOS*

Les résultats de cette étude ont des implications importantes pour la gestion de l'organisation ils suggèrent que la banque devrait accorder une attention particulière au développement de leur système de contrôle de gestion formel. Un système de contrôle de gestion formel efficace peut favoriser le partage des connaissances et l'apprentissage organisationnel, qui sont des facteurs importants de la performance globale.

Cette figure présente les résultats de notre étude qui a examiné les relations entre le système de contrôle de gestion (SGC), le partage des connaissances (KowMgt), l'apprentissage organisationnel (Lern) et la performance organisationnelle (Perform).

**Figure 2 : Résultats de l'analyse structurelle**



*Source : Outputs Amos*

L'impact du système de contrôle de gestion formel sur le partage des connaissances est négatif et non significatif (estimate = -0.15). De même, l'effet du contrôle de gestion formel sur l'apprentissage organisationnel, évalué à 0.10, n'est pas significatif. En revanche, l'impact du système de contrôle de gestion informel sur le partage des connaissances, mesuré à 0.22, ainsi que sur l'apprentissage organisationnel, évalué à 29%, se révèle significatif. Ainsi, l'apprentissage organisationnel contribue à 47% à la performance globale de la banque, démontrant que la banque acquiert des connaissances, des processus et du savoir-faire pour atteindre la performance.

La performance globale de la banque est influencée par l'apprentissage organisationnel à hauteur de 47% et par le partage des connaissances à hauteur de 26%. Il en découle que la banque exerce un

contrôle et mesure ses réalisations davantage par le biais du contrôle de gestion informel que par le contrôle de gestion formel.

### 3.1.5. Discussion des résultats

#### 3.1.5.1. Relation entre le système de contrôle de gestion formel et partage de connaissances

Le coefficient de corrélation entre ces deux variables est négatif ( $CR = -1,413$ ) et non significatif ( $p = 0,158$ )

➔ **H1a est fausse**

#### 3.1.5.2. Relation entre le système de contrôle de gestion formel et l'apprentissage organisationnel

Il existe une relation positive mais non significative entre le système de contrôle de gestion formel et l'apprentissage organisationnel, avec un coefficient de corrélation  $CR = 0,958 < 1,96$  et  $p = 0,338 > 0,05$ .

➔ **H1b est fausse**

#### 3.1.5.3. La relation entre le système de contrôle de gestion informel et le partage des connaissances

Le « système de contrôle de gestion informel » a un impact positif sur le partage des connaissances avec un coefficient de corrélation  $CR = 2,028 > 1,96$  et  $p = 0,043 < 0,05$

➔ **H2a est vrai**

#### 3.1.5.4. La relation entre système de contrôle de gestion informel et l'apprentissage organisationnel

Les résultats issus de l'analyse confirmatoire de notre recherche nous ont permis de valider notre quatrième hypothèse de recherche avec un coefficient de corrélation  $CR = 2,768 > 1,96$  et  $p = 0,006 < 0,05$ .

➔ **H2b est vrai**

#### 3.1.5.5. La relation entre le partage de connaissance et la performance globale

L'analyse confirmatoire de notre recherche a permis de valider notre cinquième hypothèse, avec un coefficient de corrélation de  $CR = 3,125 > 1,96$  et  $p = 0,002 < 0,05$ .

➔ **H3 est vrai**

#### 3.1.5.6. La relation entre l'apprentissage organisationnel et la performance globale

Les résultats de l'analyse confirmatoire de notre recherche nous ont permis de valider notre cinquième hypothèse de recherche avec un coefficient de corrélation  $CR = 5,658 > 1,96$  et  $p = 0,000 < 0,05$ .

➔ **H4 est vrai**

### Recommandations et limites

Les données analysées indiquent que le contrôle de gestion informel exerce une influence plus significative sur la performance globale de la banque que le contrôle de gestion formel. Cela signifie que les interactions informelles entre les employés, les pratiques de travail et les normes sociales ont un impact plus important sur la performance de la banque que les systèmes formels de contrôle de gestion tels que les budgets et les rapports financiers.

Cependant, pour améliorer la cohérence des objectifs et des processus, la banque pourrait envisager de renforcer son contrôle de gestion formel. À cette fin, nous recommandons l'utilisation de la Business Intelligence (BI) et l'implémentation du tableau de bord prospectif, un outil de pilotage de la performance conçu pour assister les organisations dans l'atteinte de leurs objectifs stratégiques.

### Conclusion

Cette étude a mis l'accent sur les résultats prédominants issus de l'analyse confirmatoire, réalisée à travers la modélisation par équations structurelles, qui a été menée pour tester nos hypothèses. Cette analyse précédée par l'analyse factorielle dont plusieurs tests préliminaires ont été effectués pour assurer l'utilisation de la modélisation telle que le test KMO, test de sphéricité de Bartlett et l'alpha de Cronbach. De plus, nos investigations ont démontré comment le système de contrôle de gestion contribue à la performance globale de la banque en intégrant le partage des connaissances et l'apprentissage organisationnel en tant que variables médiatrices.

Les conclusions de cette analyse suggèrent que l'influence du contrôle de gestion informel sur la performance globale de la banque est plus marquée que celle du contrôle de gestion formel. En conséquence, nous préconisons l'adoption de la Business Intelligence (BI) et la mise en oeuvre du tableau de bord prospectif pour renforcer les lacunes du contrôle de gestion formel, soulignant ainsi l'importance de cet outil moderne de pilotage.

## Références Bibliographiques

---

- Alavi, M., & Leidner, D. E. (2001). Knowledge management and knowledge management systems: Conceptual foundations and research issues. *MIS quarterly*, 107-136.
- Aubert, B. A. (2004). *Mesure intégrée du risque dans les organisations*. PUM.
- Baker, W. E., & Sinkula, J. M. (2007). Does market orientation facilitate balanced innovation programs ? An organizational learning perspective. *Journal of product innovation management*, 24(4), 316-334.
- Bontis, N. (2002). There is a price on your head: Managing intellectual capital strategically. *Business Quarterly*, 60(4), 40-47.
- Cravens, D. W., Lassk, F. G., Low, G. S., Marshall, G. W., & Moncrief, W. C. (2004). Formal and informal management control combinations in sales organizations: The impact on salesperson consequences. *Journal of Business Research*, 57(3), 241-248.
- Dickson, P. R. (1996). The static and dynamic mechanics of competition: a comment on Hunt and Morgan's comparative advantage theory. *Journal of marketing*, 60(4), 102-106.
- El Haouary, O., & Skouri, A. (2019). La relation contrôle de gestion-Apprentissage organisationnel : Une étude exploratoire. *Revue du Contrôle de la Comptabilité et de l'Audit*, 4(10), p-297.
- Guibert, N., & Dupuy, Y. (1997). La complémentarité entre contrôle « formel » et contrôle « informel » : le cas de la relation client-fournisseur. *Comptabilité-Contrôle-Audit*, 3(1), 39-52.
- Guibert, N., & Dupuy, Y. (1997). La complémentarité entre contrôle « formel » et contrôle « informel » : le cas de la relation client-fournisseur. *Comptabilité-Contrôle-Audit*, 3(1), 39-52.
- Hansen M.T. Mors M.L. et Lovas B. (2005). "Knowledge sharing in organizations: A relational perspective", *Academy of Management Journal*, vol. 48, p. 776-795.
- Jaworski, B. J., Stathakopoulos, V., & Krishnan, H. S. (1993). Control combinations in marketing : conceptual framework and empirical evidence. *Journal of marketing*, 57(1), 57-69.
- Jaworski, B. J., Stathakopoulos, V., & Krishnan, H. S. (1993). Control combinations in marketing : conceptual framework and empirical evidence. *Journal of marketing*, 57(1), 57-69.
- Jerez-Gomez, P., Céspedes-Lorente, J., & Valle-Cabrera, R. (2005). Organizational learning capability: a proposal of measurement. *Journal of business research*, 58(6), 715-725.
- Kaplan, R & Norton, D. (1998). *Comment utiliser un tableau de bord prospectif*, édition Eyrolles, sixième tirage, 2007.
- Kloot, L. (1997). Organizational learning and management control systems: responding to environmental change. *Management Accounting Research*, 8(1), 47-73.
- Lee, H., & Choi, B. (2003). Knowledge management enablers, processes, and organizational performance : An integrative view and empirical examination. *Journal of management information systems*, 20(1), 179-228.
- Malmi, T. et Brown, D. A. (2008). Management control systems as a package-Opportunities, challenges and research directions. *Management accounting research*, 19(4), 287-300.
- MESSAOUDI, A., karim LAHLIMI, Y., & BENALLA, O. (2021). Apprentissage organisationnel, innovation managériale, avantage compétitif et performance : Une relation à questionner. *Alternatives Managériales Economiques*, 3(1), 331-352.
- Simons, R. (1995). *Levers of control : How managers use innovative control systems to drive strategic renewal*. Harvard Business Press.

## Annexe 1 : Echelle de mesure

Variables	Items	Enoncés	Références
<b>Ces questions sont relatives à votre perception des pratiques de contrôle de gestion au niveau de votre banque : Dans quelle mesure l'unité contrôle de gestion utilise-t-elle les pratiques suivantes ?</b>			
<b>Contrôle formel</b>	<b>MCGform1</b>	Evaluation et contrôle opérationnel par le tableau de bord financier	(Kallunki, J. P., Laitinen, E. K., & Silvola, H, 2011)
	<b>MCGform2</b>	Evaluation et contrôle des choix stratégiques par le tableau de bord prospectif	
	<b>MCGform2</b>	Budgétisation flexible ou Budgétisation suivant le niveau de l'activité	
	<b>MCGform3</b>	Calcul des indicateurs de suivi par les méthodes de la comptabilité analytique de gestion : Coût basé sur l'activité, Coûts standards, ou Coût marginal.	
	<b>MCGform4</b>	Utilisation du taux de cession interne/valeur présente pour le calcul de la rentabilité des agences bancaires en utilisant la technique de pool unique ou de pool multiple	
	<b>MCGform5</b>	Utilisation du taux de cession interne/valeur présente pour le calcul de la rentabilité des agences bancaires en utilisant la technique de pool unique ou de pool multiple	
	<b>MCGform6</b>	Utilisation des statistiques dans le contrôle de gestion	
	<b>MCGform7</b>	Utilisation des statistiques dans le contrôle de gestion	
<b>MCS - Contrôle informel</b>	<b>MCGinf1</b>	Accent mis sur le consensus et la prise de décision participative du personnel	(Kallunki, J. P., Laitinen, E. K., & Silvola, H, 2011)
	<b>MCGinf2</b>	Accent sur l'adaptation sans souci de la pratique passée	
	<b>MCGinf3</b>	Canaux de communication ouverts et flux libres d'informations	
	<b>MCGinf4</b>	Accent mis sur l'initiative et l'adaptation à la situation actuelle	
	<b>MCGinf5</b>	Accès informel facile aux cadres supérieurs	
	<b>MCGinf6</b>	Les gestionnaires sont encouragés à développer de nouvelles idées bien qu'elles ne relèvent pas du domaine de leur responsabilité	

	<b>MCGinf7</b>	Tolérance des erreurs du gestionnaire, apprentissage et partage des leçons apprises d'eux	
	<b>MCGinf8</b>	Les gestionnaires partagent des informations avec des collègues	
	<b>MCGinf9</b>	Réaction rapide pour saisir des opportunités inattendues	
	<b>MCGinf10</b>	La culture de l'entreprise actuelle encourage la signalisation informelle des problèmes potentiels	
<b>Ces questions sont relatives à votre perception de l'apprentissage organisationnel</b>			
<b>Apprentissage organisationnel</b>	<b>orgLern1</b>	Notre organisation a acquis des connaissances nouvelles et importantes au cours des trois dernières années	(Ramírez, A. M., Morales, V. J. G., & Rojas, R. M, 2011)
	<b>orgLern2</b>	Les membres de notre organisation ont acquis des compétences spécifiques au cours des trois dernières années.	
	<b>orgLern3</b>	L'amélioration de notre organisation a été influencée par les nouvelles connaissances acquises au cours des trois dernières années.	
	<b>orgLern4</b>	Notre organisation est un lieu d'apprentissage	
<b>Ces questions sont relatives à votre perception de la performance non financière</b>			
Par rapport à la moyenne du secteur, comment décririez-vous la performance de votre unité en fonction des indicateurs suivants ?			
<b>Performance non financiers</b>	<b>NoFinP1</b>	Satisfaction des clients	(Prieto, I. M., & Revilla, E, 2006)
	<b>NoFinP2</b>	Augmentation du nombre de clients	
	<b>NoFinP3</b>	La satisfaction des employés	
	<b>NoFinP4</b>	Qualité des produits et des services offerts	
	<b>NoFinP5</b>	Réputation organisationnelle	
	<b>NoFinP6</b>	Rétention des clients	(Bisbe, J., & Otley, D, 2004)
<b>Ces questions sont relatives à votre perception de la performance financière</b>			
En comparaison avec la moyenne du secteur, votre organisation a obtenu des performances élevées mesurées par :			
<b>la performance financière</b>	<b>FinPerf1</b>	la performance financière	(Kallunki, J. P., Laitinen, E. K., & Silvola, H, 2011)
	<b>FinPerf2</b>	Retour sur investissement (ROI)	
	<b>FinPerf3</b>	Rendement des actifs (ROA)	
	<b>FinPerf4</b>	Amélioration de la productivité du travail	(Prieto, I. M., & Revilla, E, 2006)
	<b>FinPerf5</b>	Produit net bancaire (rentabilité)	(Bisbe, J., & Otley, D, 2004)
	<b>FinPerf6</b>	Augmentation de la part de marché	
	<b>FinPerf7</b>	Taux de croissance des bénéfices	
<b>Ces questions sont relatives à la perception du partage des connaissances (knowledge sharing)</b>			

<b>Le partage des connaissances</b>	<b>KowShr1</b>	Lorsque j'apprends à résoudre des problèmes liés à mon travail, j'informe les autres collègues	
	<b>KowShr2</b>	Partager les connaissances sur le processus de travail est une habitude dans mon organisation	
	<b>KowShr3</b>	Je n'ai aucune inquiétude à partager ma connaissance du processus de travail avec mes collègues, quand ils le demandent	
	<b>KowShr4</b>	Les dirigeants de mon organisation sont disposés à partager leurs connaissances sur les processus de travail lorsque je demande de l'aide.	
	<b>KowShr5</b>	Les dirigeants de mon organisation sont disposés à partager leurs compétences sur les processus de travail lorsque je demande de l'aide	
	<b>KowShr6</b>	Les membres de notre équipe partagent leurs connaissances et leur expertise particulières les uns avec les autres.	
	<b>KowShr7</b>	Les membres de l'équipe les plus compétents fournissent librement aux autres membres des connaissances ou des compétences spécialisées difficiles à trouver	



## Annexe 2 : Statistiques du Total des Items

## Descriptive Statistics

	Mean	Std. Deviation	Analysis N
MCGform1	5.0200	1.32558	100
MCGform2	4.9900	1.38895	100
MCGform3	4.9300	1.40169	100
MCGform4	5.0300	1.57925	100
MCGform5	5.0700	1.25734	100
MCGform6	5.1200	1.41621	100
MCGform7	5.0500	1.47966	100
MCGinf1	4.5500	1.42400	100
MCGinf2	4.4400	1.23354	100
MCGinf3	4.6400	1.57967	100
MCGinf4	4.7700	1.33979	100
MCGinf5	4.6000	1.39986	100
MCGinf6	4.4000	1.68175	100
MCGinf7	4.7700	1.37698	100
MCGinf8	4.8600	1.62070	100
MCGinf9	4.7100	1.63482	100
MCGinf10	4.5100	1.36696	100
orgLern1	4.8200	1.44516	100
orgLern2	4.7400	1.41863	100
orgLern3	4.8400	1.39059	100
orgLern4	4.9600	1.55648	100
NoFinP1	4.7900	1.28939	100
NoFinP2	4.3400	1.65279	100
NoFinP3	4.4000	1.66363	100
NoFinP4	4.6700	1.21485	100
NoFinP5	4.5500	1.65374	100
NoFinP6	4.41000	1.518206	100
FinPerf1	4.5500	1.41689	100
FinPerf2	4.4000	1.63917	100
FinPerf3	4.2400	1.67042	100
FinPerf4	4.4800	1.74934	100
FinPerf5	4.9200	1.44026	100
FinPerf6	4.3300	1.76987	100
FinPerf7	4.4200	1.67682	100
FinPerf8	4.5600	1.82198	100
KowShr1	5.2500	1.18386	100
KowShr2	5.1200	1.11265	100
KowShr3	5.4600	1.28252	100
KowShr4	5.2600	1.43984	100
KowShr5	5.2700	1.44148	100
KowShr6	5.5100	1.26726	100
KowShr7	5.6100	1.17975	100

Annexe 3 : Matrices de structure

Pattern Matrix<sup>a</sup>

	Component				
	1	2	3	4	5
MCGform1			.909		
MCGform2			.880		
MCGform3			.881		
MCGform4			.900		
MCGform5			.843		
MCGform6			.925		
MCGform7			.812		
MCGinf1		.800			
MCGinf2		.891			
MCGinf3		.752			
MCGinf4		.618			
MCGinf5		.872			
MCGinf6		.727			
MCGinf7		.961			
MCGinf8		.760			
MCGinf9		.644			
MCGinf10		.686			
orgLern1					.912
orgLern2					.953
orgLern3					.931
orgLern4					.996
NoFinP1	.861				
NoFinP2	.674				
NoFinP3	.819				
NoFinP4	.905				
NoFinP5	.741				
NoFinP6	.530				
FinPerf1	.904				
FinPerf2	.910				
FinPerf3	.796				
FinPerf4	.879				
FinPerf5	.937				
FinPerf6	.883				
FinPerf7	.796				
FinPerf8	.908				
KowShr1				.892	
KowShr2				.826	
KowShr3				.853	
KowShr4				.805	
KowShr5				.756	
KowShr6				.876	
KowShr7				.786	

Extraction Method: Principal Component Analysis.

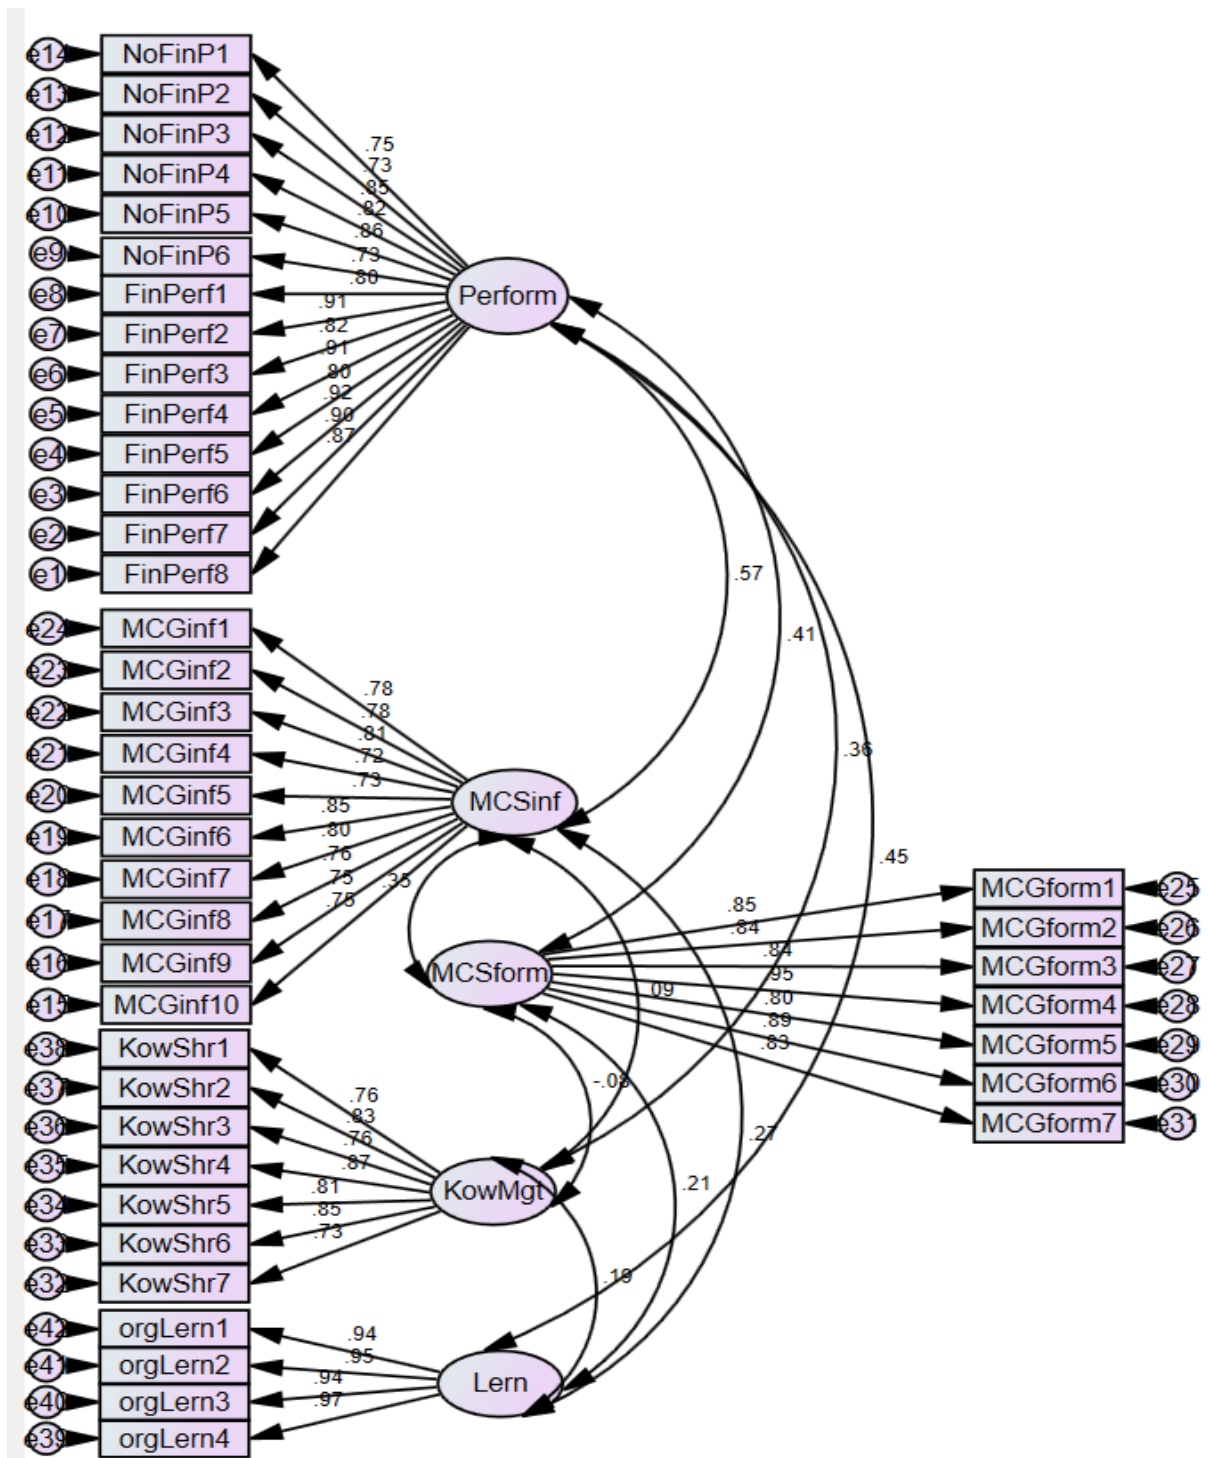
Rotation Method: Promax with Kaiser Normalization.

a. Rotation converged in 6 iterations.

Annexe 4 : Mesure de fiabilité avec alpha de Cronbach

1	Reliability Statistics	Item-Total Statistics																																																																																																
	<table border="1"> <thead> <tr> <th>Cronbach's Alpha</th> <th>Cronbach's Alpha Based on Standardized Items</th> <th>N of Items</th> </tr> </thead> <tbody> <tr> <td>.951</td> <td>.951</td> <td>7</td> </tr> </tbody> </table>	Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items	.951	.951	7	<table border="1"> <thead> <tr> <th></th> <th>Scale Mean if Item Deleted</th> <th>Scale Variance if Item Deleted</th> <th>Corrected Item-Total Correlation</th> <th>Squared Multiple Correlation</th> <th>Cronbach's Alpha if Item Deleted</th> </tr> </thead> <tbody> <tr><td>MCGform1</td><td>30.1900</td><td>56.782</td><td>.841</td><td>.718</td><td>.943</td></tr> <tr><td>MCGform2</td><td>30.2200</td><td>56.497</td><td>.810</td><td>.726</td><td>.945</td></tr> <tr><td>MCGform3</td><td>30.2800</td><td>56.082</td><td>.824</td><td>.689</td><td>.944</td></tr> <tr><td>MCGform4</td><td>30.1800</td><td>52.048</td><td>.913</td><td>.862</td><td>.937</td></tr> <tr><td>MCGform5</td><td>30.1400</td><td>58.788</td><td>.776</td><td>.676</td><td>.948</td></tr> <tr><td>MCGform6</td><td>30.0900</td><td>55.073</td><td>.869</td><td>.842</td><td>.940</td></tr> <tr><td>MCGform7</td><td>30.1600</td><td>55.348</td><td>.809</td><td>.741</td><td>.946</td></tr> </tbody> </table>		Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted	MCGform1	30.1900	56.782	.841	.718	.943	MCGform2	30.2200	56.497	.810	.726	.945	MCGform3	30.2800	56.082	.824	.689	.944	MCGform4	30.1800	52.048	.913	.862	.937	MCGform5	30.1400	58.788	.776	.676	.948	MCGform6	30.0900	55.073	.869	.842	.940	MCGform7	30.1600	55.348	.809	.741	.946																																										
Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items																																																																																																
.951	.951	7																																																																																																
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted																																																																																													
MCGform1	30.1900	56.782	.841	.718	.943																																																																																													
MCGform2	30.2200	56.497	.810	.726	.945																																																																																													
MCGform3	30.2800	56.082	.824	.689	.944																																																																																													
MCGform4	30.1800	52.048	.913	.862	.937																																																																																													
MCGform5	30.1400	58.788	.776	.676	.948																																																																																													
MCGform6	30.0900	55.073	.869	.842	.940																																																																																													
MCGform7	30.1600	55.348	.809	.741	.946																																																																																													
2	<table border="1"> <thead> <tr> <th>Cronbach's Alpha</th> <th>Cronbach's Alpha Based on Standardized Items</th> <th>N of Items</th> </tr> </thead> <tbody> <tr> <td>.936</td> <td>.937</td> <td>10</td> </tr> </tbody> </table>	Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items	.936	.937	10	<table border="1"> <thead> <tr> <th></th> <th>Scale Mean if Item Deleted</th> <th>Scale Variance if Item Deleted</th> <th>Corrected Item-Total Correlation</th> <th>Squared Multiple Correlation</th> <th>Cronbach's Alpha if Item Deleted</th> </tr> </thead> <tbody> <tr><td>MCGinf1</td><td>41.7000</td><td>112.697</td><td>.750</td><td>.716</td><td>.929</td></tr> <tr><td>MCGinf2</td><td>41.8100</td><td>115.428</td><td>.772</td><td>.815</td><td>.928</td></tr> <tr><td>MCGinf3</td><td>41.6100</td><td>109.109</td><td>.782</td><td>.665</td><td>.927</td></tr> <tr><td>MCGinf4</td><td>41.4800</td><td>115.686</td><td>.691</td><td>.581</td><td>.932</td></tr> <tr><td>MCGinf5</td><td>41.6500</td><td>114.210</td><td>.710</td><td>.791</td><td>.931</td></tr> <tr><td>MCGinf6</td><td>41.8500</td><td>106.331</td><td>.814</td><td>.730</td><td>.925</td></tr> <tr><td>MCGinf7</td><td>41.4800</td><td>112.636</td><td>.782</td><td>.734</td><td>.927</td></tr> <tr><td>MCGinf8</td><td>41.3900</td><td>109.897</td><td>.732</td><td>.567</td><td>.930</td></tr> <tr><td>MCGinf9</td><td>41.5400</td><td>110.271</td><td>.712</td><td>.595</td><td>.931</td></tr> <tr><td>MCGinf10</td><td>41.7400</td><td>114.639</td><td>.714</td><td>.578</td><td>.930</td></tr> </tbody> </table>		Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted	MCGinf1	41.7000	112.697	.750	.716	.929	MCGinf2	41.8100	115.428	.772	.815	.928	MCGinf3	41.6100	109.109	.782	.665	.927	MCGinf4	41.4800	115.686	.691	.581	.932	MCGinf5	41.6500	114.210	.710	.791	.931	MCGinf6	41.8500	106.331	.814	.730	.925	MCGinf7	41.4800	112.636	.782	.734	.927	MCGinf8	41.3900	109.897	.732	.567	.930	MCGinf9	41.5400	110.271	.712	.595	.931	MCGinf10	41.7400	114.639	.714	.578	.930																								
Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items																																																																																																
.936	.937	10																																																																																																
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted																																																																																													
MCGinf1	41.7000	112.697	.750	.716	.929																																																																																													
MCGinf2	41.8100	115.428	.772	.815	.928																																																																																													
MCGinf3	41.6100	109.109	.782	.665	.927																																																																																													
MCGinf4	41.4800	115.686	.691	.581	.932																																																																																													
MCGinf5	41.6500	114.210	.710	.791	.931																																																																																													
MCGinf6	41.8500	106.331	.814	.730	.925																																																																																													
MCGinf7	41.4800	112.636	.782	.734	.927																																																																																													
MCGinf8	41.3900	109.897	.732	.567	.930																																																																																													
MCGinf9	41.5400	110.271	.712	.595	.931																																																																																													
MCGinf10	41.7400	114.639	.714	.578	.930																																																																																													
3	<table border="1"> <thead> <tr> <th>Cronbach's Alpha</th> <th>Cronbach's Alpha Based on Standardized Items</th> <th>N of Items</th> </tr> </thead> <tbody> <tr> <td>.973</td> <td>.973</td> <td>4</td> </tr> </tbody> </table>	Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items	.973	.973	4	<table border="1"> <thead> <tr> <th></th> <th>Scale Mean if Item Deleted</th> <th>Scale Variance if Item Deleted</th> <th>Corrected Item-Total Correlation</th> <th>Squared Multiple Correlation</th> <th>Cronbach's Alpha if Item Deleted</th> </tr> </thead> <tbody> <tr><td>orgLern1</td><td>14.5400</td><td>17.887</td><td>.923</td><td>.853</td><td>.966</td></tr> <tr><td>orgLern2</td><td>14.6200</td><td>18.056</td><td>.929</td><td>.876</td><td>.965</td></tr> <tr><td>orgLern3</td><td>14.5200</td><td>18.333</td><td>.923</td><td>.861</td><td>.966</td></tr> <tr><td>orgLern4</td><td>14.4000</td><td>16.707</td><td>.954</td><td>.914</td><td>.958</td></tr> </tbody> </table>		Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted	orgLern1	14.5400	17.887	.923	.853	.966	orgLern2	14.6200	18.056	.929	.876	.965	orgLern3	14.5200	18.333	.923	.861	.966	orgLern4	14.4000	16.707	.954	.914	.958																																																												
Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items																																																																																																
.973	.973	4																																																																																																
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted																																																																																													
orgLern1	14.5400	17.887	.923	.853	.966																																																																																													
orgLern2	14.6200	18.056	.929	.876	.965																																																																																													
orgLern3	14.5200	18.333	.923	.861	.966																																																																																													
orgLern4	14.4000	16.707	.954	.914	.958																																																																																													
4	<table border="1"> <thead> <tr> <th>Cronbach's Alpha</th> <th>Cronbach's Alpha Based on Standardized Items</th> <th>N of Items</th> </tr> </thead> <tbody> <tr> <td>.926</td> <td>.927</td> <td>7</td> </tr> </tbody> </table>	Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items	.926	.927	7	<table border="1"> <thead> <tr> <th></th> <th>Scale Mean if Item Deleted</th> <th>Scale Variance if Item Deleted</th> <th>Corrected Item-Total Correlation</th> <th>Squared Multiple Correlation</th> <th>Cronbach's Alpha if Item Deleted</th> </tr> </thead> <tbody> <tr><td>KowShr1</td><td>32.2300</td><td>42.522</td><td>.740</td><td>.633</td><td>.917</td></tr> <tr><td>KowShr2</td><td>32.3600</td><td>42.556</td><td>.796</td><td>.668</td><td>.913</td></tr> <tr><td>KowShr3</td><td>32.0200</td><td>41.555</td><td>.734</td><td>.549</td><td>.917</td></tr> <tr><td>KowShr4</td><td>32.2200</td><td>38.456</td><td>.830</td><td>.775</td><td>.908</td></tr> <tr><td>KowShr5</td><td>32.2100</td><td>39.622</td><td>.752</td><td>.739</td><td>.917</td></tr> <tr><td>KowShr6</td><td>31.9700</td><td>40.454</td><td>.824</td><td>.692</td><td>.908</td></tr> <tr><td>KowShr7</td><td>31.8700</td><td>42.983</td><td>.709</td><td>.551</td><td>.920</td></tr> </tbody> </table>		Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted	KowShr1	32.2300	42.522	.740	.633	.917	KowShr2	32.3600	42.556	.796	.668	.913	KowShr3	32.0200	41.555	.734	.549	.917	KowShr4	32.2200	38.456	.830	.775	.908	KowShr5	32.2100	39.622	.752	.739	.917	KowShr6	31.9700	40.454	.824	.692	.908	KowShr7	31.8700	42.983	.709	.551	.920																																										
Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items																																																																																																
.926	.927	7																																																																																																
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted																																																																																													
KowShr1	32.2300	42.522	.740	.633	.917																																																																																													
KowShr2	32.3600	42.556	.796	.668	.913																																																																																													
KowShr3	32.0200	41.555	.734	.549	.917																																																																																													
KowShr4	32.2200	38.456	.830	.775	.908																																																																																													
KowShr5	32.2100	39.622	.752	.739	.917																																																																																													
KowShr6	31.9700	40.454	.824	.692	.908																																																																																													
KowShr7	31.8700	42.983	.709	.551	.920																																																																																													
5	<table border="1"> <thead> <tr> <th>Cronbach's Alpha</th> <th>Cronbach's Alpha Based on Standardized Items</th> <th>N of Items</th> </tr> </thead> <tbody> <tr> <td>.970</td> <td>.970</td> <td>14</td> </tr> </tbody> </table>	Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items	.970	.970	14	<table border="1"> <thead> <tr> <th></th> <th>Scale Mean if Item Deleted</th> <th>Scale Variance if Item Deleted</th> <th>Corrected Item-Total Correlation</th> <th>Squared Multiple Correlation</th> <th>Cronbach's Alpha if Item Deleted</th> </tr> </thead> <tbody> <tr><td>NoFinP1</td><td>58.27000</td><td>320.058</td><td>.761</td><td>.732</td><td>.969</td></tr> <tr><td>NoFinP2</td><td>58.72000</td><td>311.901</td><td>.723</td><td>.724</td><td>.969</td></tr> <tr><td>NoFinP3</td><td>58.66000</td><td>304.974</td><td>.845</td><td>.754</td><td>.967</td></tr> <tr><td>NoFinP4</td><td>58.39000</td><td>320.483</td><td>.802</td><td>.729</td><td>.968</td></tr> <tr><td>NoFinP5</td><td>58.51000</td><td>305.768</td><td>.836</td><td>.781</td><td>.967</td></tr> <tr><td>NoFinP6</td><td>58.65000</td><td>315.563</td><td>.722</td><td>.689</td><td>.969</td></tr> <tr><td>FinPerf1</td><td>58.51000</td><td>313.990</td><td>.813</td><td>.796</td><td>.968</td></tr> <tr><td>FinPerf2</td><td>58.66000</td><td>302.651</td><td>.903</td><td>.889</td><td>.966</td></tr> <tr><td>FinPerf3</td><td>58.82000</td><td>306.472</td><td>.813</td><td>.829</td><td>.967</td></tr> <tr><td>FinPerf4</td><td>58.58000</td><td>299.398</td><td>.898</td><td>.876</td><td>.966</td></tr> <tr><td>FinPerf5</td><td>58.14000</td><td>314.627</td><td>.785</td><td>.768</td><td>.968</td></tr> <tr><td>FinPerf6</td><td>58.73000</td><td>298.846</td><td>.896</td><td>.931</td><td>.966</td></tr> <tr><td>FinPerf7</td><td>58.64000</td><td>302.899</td><td>.876</td><td>.916</td><td>.966</td></tr> <tr><td>FinPerf8</td><td>58.50000</td><td>299.828</td><td>.851</td><td>.836</td><td>.967</td></tr> </tbody> </table>		Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted	NoFinP1	58.27000	320.058	.761	.732	.969	NoFinP2	58.72000	311.901	.723	.724	.969	NoFinP3	58.66000	304.974	.845	.754	.967	NoFinP4	58.39000	320.483	.802	.729	.968	NoFinP5	58.51000	305.768	.836	.781	.967	NoFinP6	58.65000	315.563	.722	.689	.969	FinPerf1	58.51000	313.990	.813	.796	.968	FinPerf2	58.66000	302.651	.903	.889	.966	FinPerf3	58.82000	306.472	.813	.829	.967	FinPerf4	58.58000	299.398	.898	.876	.966	FinPerf5	58.14000	314.627	.785	.768	.968	FinPerf6	58.73000	298.846	.896	.931	.966	FinPerf7	58.64000	302.899	.876	.916	.966	FinPerf8	58.50000	299.828	.851	.836	.967
Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items																																																																																																
.970	.970	14																																																																																																
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted																																																																																													
NoFinP1	58.27000	320.058	.761	.732	.969																																																																																													
NoFinP2	58.72000	311.901	.723	.724	.969																																																																																													
NoFinP3	58.66000	304.974	.845	.754	.967																																																																																													
NoFinP4	58.39000	320.483	.802	.729	.968																																																																																													
NoFinP5	58.51000	305.768	.836	.781	.967																																																																																													
NoFinP6	58.65000	315.563	.722	.689	.969																																																																																													
FinPerf1	58.51000	313.990	.813	.796	.968																																																																																													
FinPerf2	58.66000	302.651	.903	.889	.966																																																																																													
FinPerf3	58.82000	306.472	.813	.829	.967																																																																																													
FinPerf4	58.58000	299.398	.898	.876	.966																																																																																													
FinPerf5	58.14000	314.627	.785	.768	.968																																																																																													
FinPerf6	58.73000	298.846	.896	.931	.966																																																																																													
FinPerf7	58.64000	302.899	.876	.916	.966																																																																																													
FinPerf8	58.50000	299.828	.851	.836	.967																																																																																													

Annexe 5 : Schéma d'analyse de covariance



## Annexe 6 : Variance totale expliquée

## Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings <sup>a</sup>
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total
1	15.663	37.292	37.292	15.663	37.292	37.292	13.994
2	6.047	14.397	51.690	6.047	14.397	51.690	9.769
3	4.129	9.831	61.520	4.129	9.831	61.520	7.807
4	3.284	7.820	69.341	3.284	7.820	69.341	6.492
5	2.724	6.485	75.826	2.724	6.485	75.826	6.791
6	.992	2.361	78.187				
7	.832	1.981	80.168				
8	.705	1.679	81.847				
9	.664	1.582	83.429				
10	.617	1.469	84.898				
11	.591	1.406	86.304				
12	.525	1.251	87.555				
13	.502	1.196	88.751				
14	.480	1.143	89.895				
15	.394	.937	90.832				
16	.371	.884	91.716				
17	.353	.842	92.558				
18	.319	.760	93.318				
19	.307	.732	94.050				
20	.278	.663	94.713				
21	.254	.604	95.317				
22	.209	.497	95.814				
23	.205	.488	96.302				
24	.186	.442	96.744				
25	.167	.397	97.141				
26	.162	.385	97.526				
27	.140	.335	97.860				
28	.117	.279	98.139				
29	.116	.275	98.415				
30	.104	.247	98.662				
31	.088	.209	98.870				
32	.076	.181	99.051				
33	.073	.174	99.225				
34	.059	.141	99.366				
35	.052	.123	99.489				
36	.048	.115	99.604				
37	.037	.087	99.692				
38	.033	.078	99.770				
39	.031	.074	99.844				
40	.026	.063	99.907				
41	.022	.053	99.960				
42	.017	.040	100.000				

Extraction Method: Principal Component Analysis.

a. When components are correlated, sums of squared loadings cannot be added to obtain a total variance.



8, Avenue Tahar Ben Ammar - El Manar II Tunis 2092



(216) 71.885.738 - (216) 71.885.211



(216) 71.884.220 - (216) 71.884.188



[ifidmag.Inst@ifid.org.tn](mailto:ifidmag.Inst@ifid.org.tn)



[www.ifid.org.tn](http://www.ifid.org.tn)