



Mémoire de fin d'Etudes

Thème :

Intuition des décideurs : Stress test inversé sur le risque du crédit de la BFPME

Présenté et soutenu par :

GHADHAB Wassim

Encadré par :

Mr. NAOUI Kamel

Etudiant(e) parrainé(e) par :

Banque de Financement des Petites et Moyennes Entreprises

REMERCIEMENTS

Je tiens à exprimer mes sincères remerciements à tous ceux qui ont contribué à la réalisation de notre mémoire, en particulier à mon encadrant, M. NAOUI Kamel, pour sa disponibilité et ses précieux conseils. Je souhaite également exprimer ma gratitude envers l'ensemble du personnel de la BFPME, notamment M. HASSINE Wajih et M. KSIAA Hamdi, pour leur précieuse assistance et leur sérieux. Nous souhaitons adresser nos chaleureux remerciements à toutes les personnes qui, de près ou de loin, ont contribué à l'élaboration de ce travail.

DEDICACES

Je dédie ce travail à :

Mes chers parents, que nulle dédicace ne puisse exprimer mes sincères sentiments.

*Leur patience illimitée, leur encouragement constant, leur inestimable aide,
témoignent de mon profond amour et respect pour leurs grands sacrifices.*

*Mes chers frères, qui ont toujours été présents avec leur soutien infaillible et leurs
encouragements constants.*

Mes aimables amis et collègues d'étude.

RESUME

L'objectif de notre travail est d'appliquer le stress test inversé sur le risque de crédit afin d'évaluer l'impact des décisions prises par les responsables sur le niveau des prêts non performants. Pour ce faire, nous avons suivi une approche en deux étapes : tout d'abord, une approche descriptive pour présenter les bases théoriques du risque de crédit et du stress test, puis une approche empirique. Dans cette approche empirique, nous avons critiqué le modèle VECM et construit un modèle BSVAR de risque de crédit plus complet. Enfin, nous avons adopté une démarche analytique pour évaluer la capacité de la banque après l'application des scénarios construits.

Les résultats de notre étude empirique indiquent une précision significative du modèle BSVAR par rapport au modèle VECM en termes de prévisions. Cela démontre l'importance de l'intégration de la matrice des effets instantanés et de la distribution à priori, qui enrichit le modèle en termes d'informations. La conception de la distribution à priori nous a conduit à la construction des scénarios qui décrivent la réaction des décideurs de la BFPME face à l'arrivée de nouvelles informations. L'analyse des résultats du stress test inversé dans le cas du choc extrême nous indique que vers la fin de l'année 2025, tous les prêts accordés seront non performants. Cependant, sur la base de l'analyse des niveaux des hyperparamètres, nous avons pu décrire cette intuition et formuler des recommandations.

Les mots clés : stress test inversé, modèle VECM, modèle BSVAR, distribution à priori, Statistique bayésienne, Matrice d'identification, scénarios.

ABSTRACT

The objective of our work is to apply the reverse stress test on credit risk to evaluate the impact of decisions made by the managers on the level of non-performing loans. To achieve this, we followed a two-step approach: firstly, a descriptive approach to present the theoretical foundations of credit risk and stress testing, and then an empirical approach. In this empirical approach, we criticized the VECM model and built a more comprehensive BSVAR model of credit risk. Finally, we adopted an analytical approach to assess the bank's capacity after the application of the constructed scenarios.

The results of our empirical study indicate a significant accuracy of the BSVAR model compared to the VECM model in terms of forecasts. This demonstrates the importance of integrating the matrix of instantaneous effects and à priori distribution, which enriches the model in terms of information. The design of the à priori distribution led us to construct scenarios that describe the reaction of BFPME decision-makers to the arrival of new information. The analysis of the results of the reverse stress test in the case of an extreme shock indicates that by the end of 2025, all granted loans will be non-performing. However, based on the analysis of hyperparameter levels, we were able to describe this intuition and formulate recommendations.

Keywords : reverse stress test, VECM model, BSVAR model, à priori distribution, Bayesian statistics, identification matrix, scenarios.

SOMMAIRE

INTRODUCTION GENERALE.....	1
CHAPITRE 1 : GENERALITE SUR LE RISQUE DU CREDIT.....	3
Introduction	4
Section 1 : Catégorisation des risques dans le secteur bancaire et analyse du risque de crédit	5
Section 2 : Les déterminants du risque de crédit.....	11
Section 3 : La réglementation du risque de crédit.....	16
Conclusion.....	24
CHAPITRE 2 : LE STRESS TEST ET GESTION DES RISQUES.....	25
Introduction	26
Section 1 : Introduction aux stress tests.....	27
Section 2 : Classification, méthodologies et modèles de stress tests.....	32
Section 3 : Mise en place des stress tests : procédures et démarches	38
Conclusion.....	43
CHAPITRE 3 : APPLICATION DU STRESS TEST DE RISQUE DE CREDIT.....	44
Introduction	45
Section 1 : Présentation et organisation de la BFPME	46
Section 2 : Modélisation du risque de crédit.....	48
Section 3 : Application du stress test sur le risque de crédit.....	67
Conclusion.....	75
CONCLUSION GENERALE.....	76

LISTE DES ABREVIATIONS

BCT	Banque Centrale Tunisienne
BFPME	Banque de Financement des Petites et Moyennes Entreprises
BRI	Banque des règlements internationaux
BSIF	Bureau du surintendant des institutions financières
BSVAR	Vectorielle Autorégressive Structurelle Bayésienne
BU	Bottom-up
CEBS	Comité européen des contrôleurs bancaires
CMLT	Crédits à moyen et long terme
DM	Test de Diebold-Mariano
EQMP	Erreur Quadratique Moyenne de Prévision
FMI	Fonds monétaire international
FSAP	Financial Sector Assessment Program
HLN	Test de la dominance de prévision
IPC	Indice des Prix à la Consommation
IPI	Indice des Prix Industrielle
LGD	Perte en cas de défaut
LogMDD	Logarithme de la densité marginale
MAE	Erreur absolue moyenne
NPL	Prêts non performants
OCDE	Organisation de coopération et de développement économiques
PCC	Provisions sur créances classées
PD	Probabilité de défaut
PIB	Produit intérieure brute
RMSE	Racine carrée de l'erreur quadratique moyenne
ROA	Ratio de rentabilité des actifs (Return on assets)
ROE	Ratio de rentabilité des capitaux propres (<i>Return on equity</i>)
RSE	Responsabilité Sociétale des Entreprises
SCAP	Supervisory Capital Assessment Program
SVAR	Structurelle Vectorielle Autorégressive
TD	Top-down
TMM	Taux du Marché Monétaire
UE	Union européenne
USD	Taux de change USD/TND
VaR	Value at Risk
VAR	Vectorielle Autorégressive
VECM	Vector Error Correction Model

LISTE DES TABLEAUX

Tableau 1 : La réglementation Bâle II.....	20
Tableau 2 : Types des modèles de stress test.....	36
Tableau 3 : Les variables micros et macros économiques.....	50
Tableau 4 : Test de la racine unitaire.....	51
Tableau 5 : Détermination du nombre des retards	52
Tableau 6 : Les résultats du Test de cointégration	52
Tableau 7 : Les résultats du Test de Causalité de Granger	55
Tableau 8 : Les résultats des simulations pour le choix de la distribution à priori	59
Tableau 9 : Les moyennes et les écarts-type des distributions à posteriori	60
Tableau 10 : Les résultats de l'indice EQMP	62
Tableau 11 : Les résultats du test de Diebold-Mariano	64
Tableau 12 : Les résultats du test de la dominance des prévisions	65
Tableau 13 : Décomposition de la variance pour les NPL	66
Tableau 14 : Les résultats des simulations pour l'intuition des décideurs	70

LISTE DES FIGURES

Figure 1 : Intégration du stress test dans la VaR.....	31
Figure 2 : L'évolution des prêts non performants.....	49
Figure 3 : Différences entre les approches fréquentiste et bayésienne.....	54
Figure 5 : EQMP des NPL.....	62
Figure 6 : Les fonctions d'impulsion.....	65
Figure 7 : Prévision des scénarios sur les NPL fin 2025.....	71
Figure 8 : Prévision cas extrême sur les NPL.....	72

INTRODUCTION GENERALE

Parmi les rôles cruciaux des banques, l'octroi de crédit se distingue comme leur activité principale. Avant d'accorder un prêt, il est impératif d'évaluer le risque d'insolvabilité de l'emprunteur, également connu sous le nom de risque de crédit. Ce risque peut être défini comme la possibilité qu'un emprunteur ne puisse pas rembourser la totalité ou une partie de son crédit conformément aux échéances convenues dans le contrat signé entre lui et l'institution prêteuse. Il convient de noter que ce type de risque a été à l'origine de plusieurs crises financières, dont la crise des subprimes aux États-Unis, qui était liée à des problèmes de non-remboursement des prêts immobiliers.

Les crises financières récentes ont clairement démontré que les méthodes de mesure des risques traditionnelles étaient insuffisantes pour faire face aux chocs extrêmes auxquels les banques peuvent être exposées. En accord avec les recommandations de certaines autorités de régulation, les institutions financières sont tenues d'effectuer régulièrement des simulations de crise afin d'estimer les pertes potentielles en cas de fluctuations dangereuses et significatives des facteurs de risque. Ces simulations de crise, également désignées sous l'appellation "scénarios de stress test", sont des outils essentiels pour évaluer les risques. Ils permettent d'établir un lien entre les décisions des responsables de la banque en réponse à l'arrivée de nouvelles informations. Cette approche facilite la mise en place de mesures correctives en cas de constatation d'impacts durables ou excessivement importants d'un scénario plausible sur le niveau des prêts non performants de la banque.

Conformément aux recommandations du Comité Bale et des autorités réglementaires en Tunisie, il est essentiel que les institutions financières et les banques effectuent régulièrement des stress tests. Cette démarche vise à prévenir les pertes potentielles et à garantir la solvabilité du secteur bancaire, surtout en période de difficultés économiques.

La Banque de Financement des Petites et Moyennes Entreprises (BFPME) a mis en place un éventail de prêts destinés au financement des secteurs stratégiques pour le développement économique et social du pays à travers l'entrepreneuriat. Toutefois, compte tenu de la situation économique du pays depuis la révolution, il est devenu essentiel d'utiliser le stress test de risque de crédit. Cette démarche vise à prévenir les perturbations potentielles susceptibles d'affecter la qualité du portefeuille de crédit et à anticiper leur impact sur la BFPME. Cette situation nous

amène à poser la question suivante : **Comment pouvons-nous utiliser l'application du stress test inversé de risque de crédit pour évaluer la capacité de résilience de la BFPME suite au choc sur la mauvaise intuition des preneurs des décisions ?**

À partir de cette problématique, nous formulons les questions secondaires suivantes :

- Quels facteurs contribuent à expliquer le risque de crédit ?
- Quels sont les limites du modèle VECM et qu'elle est la modélisation convenable au contexte du stress test et qui prend en considérations ses limites ?
- Dans qu'elle mesure l'intégration du modèle BSVAR permet d'améliorer la précision des prévisions ?
- Quelles sont les procédures pour mettre en place des stress tests inversé de risque de crédit provenant de l'intuition des preneurs des décisions ?
- Quel est l'impact des scénarios défavorables appliqués sur le risque de crédit de la BFPME ?

Pour aborder cette problématique, nous chercherons à développer un modèle de risque de crédit spécifique à la BFPME en tant qu'une banque de développement. Ce modèle nous permettra de sélectionner les distributions à priori pour la création de scénarios de stress tests, ainsi que d'anticiper leur impact sur le risque de crédit, afin d'évaluer la capacité de résilience de la banque. Notre démarche de recherche se compose des étapes suivantes :

- Dans le premier chapitre, nous explorerons les différents types de risques bancaires en général, en mettant l'accent sur le risque de crédit, tout en examinant les réglementations internationales et nationales qui le régissent.
- Le deuxième chapitre sera dédié à l'analyse du stress test, comprenant sa typologie, son modèle, et son approche. Nous nous pencherons ensuite sur les procédures pour l'application des stress tests en matière de risque de crédit.
- Le troisième et dernier chapitre se concentrera sur notre étude empirique. Nous y détaillerons les méthodes que nous avons utilisées, présenterons les résultats issus de notre modèle, et les interpréterons. De plus, nous analyserons l'impact des scénarios que nous avons élaborés sur le risque de crédit afin de déterminer les recommandations nécessaires à prendre en compte par la BFPME.

CHAPITRE 1 : GENERALITE SUR LE RISQUE DU CREDIT

CHAPITRE 1 : GENERALITE SUR LE RISQUE DU CREDIT

Introduction

L'environnement bancaire est confronté à une instabilité croissante et à une vulnérabilité accrue en raison des fluctuations monétaires. Face à ces perturbations, les banques sont de plus en plus exposées à une diversité de risques qui peuvent nuire à leur activité et à leur position sur le marché financier. Le risque est une situation ou une activité exposée à un danger potentiel.

Les banques sont confrontées à divers risques, parmi lesquels le risque de crédit. Une gestion inadéquate des risques liés au portefeuille de crédit ou une négligence des fluctuations économiques ou d'autres circonstances susceptibles d'affecter la qualité du portefeuille de crédit peuvent entraîner une détérioration de la solvabilité de la banque. Il est essentiel de prêter une attention particulière à ces risques pour maintenir la stabilité financière et assurer une gestion prudente des actifs et des engagements de crédit.

Dans ce chapitre, nous mettrons l'accent sur le risque de crédit et ses facteurs déterminants. Tout d'abord, nous présenterons différents types de risques en identifiant spécifiquement le risque de crédit. Ensuite, nous nous concentrerons sur les éléments qui influencent le risque de crédit. Enfin, nous examinerons l'environnement réglementaire du risque de crédit, à la fois au niveau international et national. L'objectif global est de comprendre en détail le risque de crédit, ses déterminants et le cadre réglementaire qui entoure ce risque, tant sur le plan national qu'international.

Section 1 : Catégorisation des risques dans le secteur bancaire et analyse du risque de crédit

Les institutions financières, en particulier les banques, sont exposées à des risques à la fois internes et externes. Les risques internes découlent de la nature spécifique de l'activité bancaire, tandis que les risques externes sont liés à l'instabilité de l'environnement économique et monétaire. Dans cette section, nous allons définir la notion de risque et présenter les risques associés à l'activité bancaire, en mettant l'accent particulièrement sur le risque de crédit.

1. Compréhension du concept de risque

Selon (Adamowicz, 2018), le risque est généralement compris comme la possibilité d'événements imprévisibles entraînant des effets indésirables. Dans le contexte bancaire, le risque est défini comme l'incertitude concernant les résultats et les pertes potentielles qui peuvent survenir lorsque l'environnement évolue de manière défavorable. Une conséquence importante de cela est que toute mesure du risque repose sur l'évaluation de ces détériorations potentielles et de leur impact sur les résultats voir (BESSIS, 1995).

Selon J. Tomaszewski, cité par (Adamowicz, 2018), le risque est défini comme une probabilité mesurable d'un événement avec des caractéristiques différentes de l'événement attendu, ayant un impact direct ou indirect sur l'écart de valeur par rapport au niveau supposé. Cette définition met l'accent sur la dimension probabiliste et statistique du risque, où l'incertitude est quantifiée en termes de probabilité d'occurrence d'événements indésirables ayant des conséquences financières.

Le risque peut être défini comme un danger potentiel associé à un événement ou à plusieurs événements. Il est caractérisé par une incertitude quant à leur survenance, mais il existe une probabilité certaine qu'ils se produisent dans une situation donnée. En d'autres termes, nous ne pouvons pas prédire avec certitude si ces événements se produiront ou non, mais il y a une possibilité réelle qu'ils se produisent, avec une certaine probabilité.

2. Typologie des risques dans le domaine bancaire

Il existe divers types de risques auxquels les banques accordent une grande attention, notamment le risque de contrepartie (ou de crédit), le risque de marché, le risque opérationnel

et le risque de liquidité. Ces risques sont considérés comme des éléments clés dans l'évaluation globale de la gestion des risques bancaires.

2.1. Le risque de marché

Le risque de marché désigne la possibilité de subir des pertes dues à des variations défavorables des taux d'intérêt, des taux de change et des prix de marché des instruments financiers, tant primaires que dérivés, détenus par la banque. Ce risque provient de l'incertitude entourant l'évolution des conditions économiques et des marchés financiers, ce qui peut entraîner une diminution de la valeur des actifs détenus par la banque et donc des pertes financières.

D'après la définition précédente, on peut conclure que le risque de marché englobe :

- **Le risque de taux d'intérêt** est l'une des principales formes de risque auxquelles les banques sont confrontées en tant qu'intermédiaires financiers. Il peut être défini comme le risque selon lequel les revenus et/ou la valeur marchande d'une banque seront affectés par les fluctuations des taux d'intérêt voir (Ballester , Ferrer, & Gonzàlez, 2009).
- **Le risque de change** se caractérise par la possibilité de subir des pertes en raison d'une évolution inattendue des taux de change. Il se traduit par des conséquences financières potentielles résultant des variations de valeur entre différentes devises. Ce risque peut se manifester lorsque la valeur d'une devise évolue de manière imprévisible par rapport à une autre. Il peut avoir un impact sur les actifs, les passifs et les transactions d'une banque, notamment dans le cadre d'opérations commerciales internationales, d'investissements à l'étranger ou d'activités de change.
- **Le risque sur les titres** se traduit par une variation défavorable des prix de certains actifs spécifiques tels que les actions et les matières premières. Il représente la possibilité de subir des pertes en raison de ces fluctuations de prix sur le marché. Les banques qui détiennent ces actifs ou sont exposées à ces produits sont exposées à un risque financier en cas de mouvements défavorables des prix.

2.2. Le risque opérationnel

Le risque opérationnel, tel que défini par le Comité de Bâle, se caractérise par des défaillances ou des lacunes au niveau des procédures, du personnel, des systèmes internes, ou suite à des événements externes. Les pertes opérationnelles, engendrées par ce risque, résultent d'un large éventail de causes, parmi lesquelles :

- Perturbations ou interruptions des activités
- Menaces et attaques terroristes
- Catastrophes naturelles
- Fraude, piratage informatique et transactions non autorisées
- Défaillances des systèmes ou des processus.

2.3. Risque de liquidité

Le risque de liquidité se réfère à la situation où une banque est incapable de répondre à ses obligations financières et de mobiliser ses actifs lorsque cela est nécessaire. Ce risque peut être provoqué par diverses situations telles que des retraits exceptionnels ou imprévus de liquidités, ainsi que le défaut de paiement d'une contrepartie. En d'autres termes, le risque de liquidité pour une banque réside dans sa capacité à disposer des liquidités nécessaires pour faire face à ses engagements et obligations financières à tout moment.

2.4. Risque pays

Le risque souverain concerne les pays en développement (risque économique) ou en transition avec une dette extérieure élevée (risque politique). Il se réfère à la possibilité de non-remboursement de la créance sur un débiteur privé ou public en raison de la situation économique et/ou politique du pays dans lequel le débiteur exerce ses activités. Il peut également être défini comme le risque de survenance d'un sinistre résultant du contexte économique et politique d'un État étranger où une entreprise ou une banque opère une partie de ses activités.

Le risque pays peut être composé de deux éléments distincts :

- **Le risque politique (pays) :** découle soit des actions ou mesures prises par les autorités publiques locales ou du pays d'origine (gouvernements, législation), soit d'événements internes tels que des émeutes, ou externes tels que des conflits ou des guerres. Cette composante est liée aux facteurs politiques qui peuvent avoir un impact sur la stabilité et la sécurité du pays, ainsi que sur les activités des entreprises et des institutions financières qui y opèrent.
- **Le risque économique et financier :** qui englobe à la fois la dépréciation de la monnaie nationale et le manque de devises étrangères, ce qui peut entraîner des conséquences telles qu'un défaut de paiement. Cette composante est liée aux facteurs économiques et financiers qui peuvent affecter la capacité d'un pays à honorer ses obligations

financières, notamment en raison de difficultés économiques, de fluctuations monétaires ou d'une pénurie de réserves de devises étrangères. Ces facteurs peuvent entraîner des retards de paiement, une instabilité financière et des difficultés pour les entreprises et les institutions financières opérant dans le pays.

2.5. Le risque d'insolvabilité

Lorsque les fonds propres d'une banque sont insuffisants pour absorber d'éventuelles pertes, cela crée un risque d'insolvabilité. La banque est également exposée à d'autres risques tels que le risque de crédit, le risque de marché et le risque de taux de change. L'exposition à ces différents risques peut mettre en péril les activités de la banque. Afin de faire face à ces engagements, les institutions financières s'efforcent constamment d'ajuster leurs fonds propres en fonction des risques encourus voir (Godlewski, 2003).

2.6. Risque systémique

Le risque systémique se réfère à la probabilité de défaillances généralisées dans un système dans son ensemble, plutôt que de pannes individuelles au niveau des composants ou des pièces. Il se manifeste par des co-mouvements (corrélation) entre la plupart ou la totalité des parties du système. Dans le domaine bancaire, le risque systémique se caractérise par une forte corrélation et une concentration des défaillances bancaires au sein d'un pays, d'un groupe de pays ou à l'échelle mondiale. Il peut également se manifester dans d'autres secteurs du secteur financier, tels que les marchés boursiers, où une baisse simultanée des prix d'un grand nombre de titres se produit sur un ou plusieurs marchés, à l'intérieur d'un seul pays ou entre pays. Le risque systémique peut être de nature domestique ou transnationale voir (Kaufman & Kenneth, 2003).

3. Évaluation et gestion du risque de crédit

Le risque de crédit, également connu sous le nom de risque de défaut de remboursement des prêts, est considéré comme le plus ancien et le principal risque auquel les banques et les institutions financières sont confrontées, et il peut causer les dommages les plus importants. En effet, le défaut de remboursement de quelques clients importants peut suffire à mettre en péril la santé financière d'une institution de crédit. C'est pourquoi les banques accordent une importance particulière à la gestion du risque de crédit afin d'éviter ses conséquences préjudiciables.

Dans cette section, nous nous concentrerons sur le risque de crédit, ses différentes composantes et les conséquences qu'il peut avoir sur une banque. Nous explorerons les mesures et les

stratégies mises en place par les institutions financières pour gérer ce risque de manière efficace et réduire les pertes potentielles associées.

3.1. Définition du risque de crédit

Selon (Audu, 2014), le risque de crédit peut être simplement défini comme la probabilité qu'un emprunteur ou une contrepartie bancaire ne respecte pas ses obligations conformément aux conditions convenues. En d'autres termes, il représente le risque de non-remboursement des prêts ou le défaut de paiement des dettes contractées. Les banques et les institutions financières doivent évaluer et gérer ce risque de manière proactive afin de minimiser les pertes financières potentielles résultant de l'incapacité des emprunteurs à honorer leurs engagements financiers.

Selon les recherches de (Spuchl'áková, Valašková, & Adamko, 2015), le risque de crédit peut être défini comme la réticence ou l'incapacité d'une contrepartie à respecter ses engagements en matière de prêt, de négociation et de règlement des transactions financières. Traditionnellement, le risque de crédit est associé à la probabilité que le débiteur d'une banque ne puisse pas rembourser le montant dû, incluant le capital et les intérêts, à ladite banque. La gestion efficace du risque de crédit est essentielle pour les institutions financières afin de minimiser les pertes et de maintenir la solidité de leur portefeuille de prêts.

3.2. Les Types du risque de crédit

Les risques de crédit peuvent être classés selon la typologie suivante :

3.2.1. Le risque de défaut

Le risque de crédit se réfère à la situation où le débiteur est incapable ou refuse d'honorer ses engagements envers le créancier, que ce soit en ce qui concerne le remboursement du principal de la dette ou le paiement des intérêts. Il est considéré comme un risque inhérent à l'activité de l'intermédiation financière traditionnelle, car il représente la défaillance potentielle de la contrepartie envers laquelle une créance ou un engagement est détenu voir (Sylvie, 2005).

Le risque de défaut est associé à la probabilité de défaillance d'un emprunteur, où celui-ci se trouve dans l'incapacité de respecter ses engagements de remboursement. Le Comité de Bâle fournit des critères et des événements qui définissent une situation de défaut pour un débiteur.

Un défaut est considéré comme étant réalisé pour un débiteur spécifique lorsqu'un ou plusieurs des événements suivants sont constatés :

- Il est probable que le débiteur ne remboursera pas intégralement ses dettes.
- Le débiteur a initié une procédure de faillite ou une procédure similaire pour se protéger de ses créanciers.

3.2.2. Le risque de dégradation du spread

Le terme "spread" désigne la différence entre le taux d'intérêt de référence, généralement celui de l'Etat considéré sans risque, et le taux d'intérêt appliqué à l'emprunteur. Il représente la prime de risque demandée par le marché pour compenser le risque associé à la contrepartie. Ainsi, le spread permet d'évaluer la qualité de l'emprunteur en mesurant la prime de risque exigée par les investisseurs.

Le risque de spread fait référence à la possibilité de détérioration de la qualité de l'emprunteur, ce qui peut avoir un impact sur les flux attendus tels que les remboursements du principal et les intérêts. L'évolution aléatoire des spreads constitue en elle-même un risque de crédit, car elle influe sur la valeur de marché du crédit. Ainsi, il n'est pas nécessaire que le défaut se concrétise pour affecter négativement la valeur d'un actif ou d'un portefeuille. Les fluctuations du spread peuvent entraîner des variations de prix sur les actifs liés au crédit, ce qui peut avoir des conséquences sur la valeur globale d'un portefeuille ou d'un actif spécifique.

3.2.3. Le risque de recouvrement

Le risque de récupération, également appelé risque de recouvrement, se réfère à l'incertitude associée au montant que la banque pourra récupérer sur une créance après le constat d'un défaut de paiement. Après qu'un débiteur ait fait défaut, la banque n'est jamais certaine du montant exact qu'elle pourra recouvrer. Ce risque découle des difficultés potentielles rencontrées lors de la récupération des fonds, telles que la liquidation d'actifs, les procédures de faillite, les négociations avec le débiteur ou les éventuelles pertes liées à la vente des actifs récupérés.

Section 2 : Les déterminants du risque de crédit

L'incidence des prêts non performants dans les banques commerciales ne se limite pas seulement à la gestion interne de la banque, mais est également liée au risque de crédit.

Les prêts non performants sont un indicateur de la qualité du crédit d'une banque et sont considérés comme un reflet de sa gestion du risque de crédit. Le ratio des prêts non performants permet de mesurer le pourcentage des pertes de crédit par rapport au montant total des prêts accordés. Il offre ainsi une indication sur la manière dont les banques gèrent leur risque de crédit, en identifiant les prêts qui présentent un niveau élevé de risque de défaut ou de non-remboursement.

La littérature a identifié deux tendances majeures qui mettent en évidence les principaux facteurs susceptibles d'influencer le risque de crédit bancaire. La première tendance souligne l'importance des variables internes en tant que déterminants potentiels du risque de crédit. Cela englobe des éléments tels que la qualité des politiques de gestion des risques de crédit au sein des banques, les pratiques de souscription des prêts, la diversification des portefeuilles de prêts, ainsi que la qualité des processus de suivi et de recouvrement des créances.

La deuxième tendance met en évidence l'évolution des variables externes, notamment les réglementations prudentielles et les conditions économiques, qui peuvent influencer le risque de crédit bancaire. Les réglementations prudentielles peuvent imposer des exigences en matière de capital et de provisions pour couvrir les pertes potentielles, ce qui peut avoir une incidence sur la gestion du risque de crédit. Par ailleurs, les conditions économiques, telles que le cycle économique, le niveau d'endettement des emprunteurs, les taux d'intérêt et la stabilité financière, peuvent également exercer une influence significative sur le risque de crédit bancaire.

En résumé, ces deux tendances soulignent l'importance de prendre en compte à la fois les facteurs internes et externes lors de l'évaluation et de la gestion du risque de crédit bancaire.

1. Facteur externe du risque de crédit

Les facteurs externes du risque de crédit sont des éléments provenant de l'environnement économique et financier dans lequel opère la banque. Ces facteurs peuvent influencer la capacité des emprunteurs à rembourser leurs dettes et augmenter le niveau de risque de crédit.

1.1. La croissance économique

La croissance économique, mesurée par le PIB, a un effet positif sur la réduction des prêts non performants. Lorsque l'économie se développe, les entreprises sont généralement en meilleure santé financière, ce qui améliore leur capacité à rembourser leurs dettes et réduit les risques des NPL. De plus, les agrégats monétaires tels que M1, M2 et M3 peuvent également jouer un rôle dans la gestion des NPL, car une augmentation de la masse monétaire peut stimuler l'activité économique et contribuer à la réduction des NPL.

1.2. Le chômage

Le chômage a un effet négatif et significatif, ce qui se traduit par une détérioration de la capacité des individus à rembourser leurs dettes, ainsi que par des entreprises ayant des flux de trésorerie faibles en raison d'une baisse de la demande pour leurs produits selon (Chaibi & Ftiti, 2015). Cette situation entraîne une diminution de la capacité de remboursement tant des emprunteurs individuels que des entreprises, ce qui peut accroître le risque de crédit.

1.3. Le taux d'intérêt

Lorsque les taux d'intérêt sont élevés, cela entraîne un fardeau de la dette plus important. Cette situation peut avoir un effet direct sur l'augmentation des créances non productives voir (Nkusu, 2011). En effet, des taux d'intérêt élevés peuvent rendre plus difficile pour les emprunteurs de rembourser leurs dettes, ce qui augmente le risque de défaut de paiement et entraîne une augmentation des créances improductives.

1.4. Le taux d'inflation

L'effet du taux d'inflation sur le risque de crédit est ambigu. Dans certains cas, des taux d'inflation plus élevés peuvent faciliter le remboursement de la dette en réduisant la valeur réelle des prêts en cours, voir (Castro, 2013). Cependant, dans les pays où les taux d'intérêt sont variables, les prêteurs ajustent les taux pour maintenir leurs rendements réels. Cela peut rendre le remboursement de la dette plus difficile, notamment pour les emprunteurs à revenu limité qui doivent faire face à des taux d'intérêt plus élevés. Par conséquent, la relation entre l'inflation et le risque de crédit peut être positive ou négative.

1.5. Le taux de change

D'après (Fofack, 2005), une appréciation de la monnaie peut avoir un impact direct sur la capacité de remboursement de la dette des particuliers en rendant les produits locaux plus chers. Cela peut rendre plus difficile pour les emprunteurs honorer leurs engagements de crédit, notamment dans les industries orientées vers l'exportation où les marges bénéficiaires peuvent être réduites. Cependant, les prêts en devises étrangères peuvent être favorisés par l'appréciation de la monnaie locale, ce qui les rend moins coûteux pour les emprunteurs voir (Nkusu, 2011). L'effet des taux de change sur les prêts non performants peut donc être positif ou négatif en fonction de la devise de la dette, et cet effet est plus prononcé dans les pays où le pourcentage de prêts en devises étrangères est élevé.

1.6. La concentration bancaire

(Kjosevski, Petkovski, & Naumovska, 2019) ont examiné la concentration bancaire comme un facteur explicatif du risque de crédit. Selon (Jiménez, Lopez, & Saurina, 2013), les banques dans un environnement concurrentiel cherchent à améliorer leur gestion des risques par rapport à leurs concurrents. Par conséquent, les pays disposant d'un secteur bancaire plus compétitif devraient avoir moins de prêts non performants. Cependant, selon (Manove, Padilla, & Pagano, 2001) et (Bolt & Tieman, 2004), une concurrence excessive peut pousser les banques à prendre des risques, tels que la réduction des critères de sélection des prêts et l'utilisation de critères de prêt moins stricts, ce qui augmente la probabilité de prêts non performants plus élevés.

2. Facteurs internes du risque de crédit

Malgré l'importance des développements macroéconomiques dans l'explication du risque de crédit, des études récentes accordent également une attention particulière à des variables spécifiques à la banque. Parmi ces variables, nous pouvons signaler :

2.1. Taille de la banque

La taille de la banque, mesurée par le total des actifs, est un facteur important utilisé pour évaluer son importance sur le marché. Cependant, les études sur la relation entre la taille des banques et les créances douteuses sont nombreuses et contradictoires. Certaines études suggèrent un impact négatif de la taille de la banque sur les prêts non performants, ce qui signifie que les grandes banques ont généralement de meilleures stratégies de gestion du risque de crédit par rapport aux banques de taille plus réduite. Cela peut s'expliquer par leur expérience

accrue et leur capacité à diversifier leur portefeuille de crédit grâce à leur part de marché plus importante.

2.2. La croissance du crédit

La croissance du crédit est souvent associée à une augmentation simultanée des prêts douteux. Les banques ayant un faible niveau de capital ont tendance à être plus risquées, car elles accordent souvent des prêts excessifs, ce qui les expose à des pertes plus élevées sur les prêts. Cependant, des études ont également montré que la relation entre le capital et le risque de crédit peut être ambigu. Même les banques disposant de ratios de fonds propres adéquats peuvent créer des portefeuilles de prêts à haut risque, ce qui peut entraîner un niveau élevé de prêts douteux. Il existe donc une variabilité dans la relation entre le capital et le risque de crédit, qui dépend des politiques de prêt spécifiques mises en place par les banques.

2.3. La rentabilité des actifs et des capitaux propres

Le ratio de rentabilité des actifs (ROA) et le ratio de rentabilité des capitaux propres (ROE) sont des mesures financières qui évaluent la rentabilité des banques. Le ROA mesure l'efficacité avec laquelle les actifs de la banque sont utilisés et indique le revenu généré par l'investissement dans ces actifs. En ce qui concerne la relation entre le ROA et les prêts non performants, différentes études ont abouti à des résultats contradictoires. Certains chercheurs, tels (Ahmad & Bashir, 2013), (Alexandri & Santoso, 2015) ont trouvé une corrélation positive entre le ROA et les prêts non performants, suggérant que les banques plus rentables sont également plus exposées à ce risque. D'autres chercheurs, comme (Messai & Jouini, 2013) ont observé une corrélation négative, indiquant que les banques les plus rentables ont tendance à avoir un niveau inférieur de prêts non performants. Cette relation peut s'expliquer par le comportement de prise de risque des banques : les banques rentables ont moins besoin d'accorder des crédits jugés risqués.

2.4. Les provisions pour pertes

Selon les recherches de (Hasan & Wall, 2004), il existe un effet positif des provisions pour pertes sur prêts sur le niveau des prêts non performants. Lorsque les banques anticipent des pertes élevées, elles tendent à accroître leurs provisions. Cette pratique de surfinancement vise à réduire la volatilité des résultats et à renforcer la solvabilité de la banque. En anticipant les pertes potentielles, les banques prennent des mesures pour se protéger contre les conséquences néfastes des prêts non performants.

2.5. Le ratio dépôts sur crédit

Le ratio dépôts sur crédit est fréquemment utilisé dans la littérature comme un indicateur de liquidité, représentant les fonds que la banque utilise pour accorder des prêts à partir des dépôts collectés. Des études telles que celles de (Dimitrios, Angelos, & Vouldis, 2012) et (Makri, Tsagkanos, & Bellas, 2014) ont démontré une relation positive entre ce ratio et le niveau des prêts non performants. Cela suggère que les banques qui ont un ratio dépôts sur crédit plus élevé ont tendance à présenter des niveaux plus élevés de prêts non performants.

Section 3 : La réglementation du risque de crédit

La fonction d'intermédiation des banques est une activité distinctive et spécifique qui est soumise à une réglementation rigoureuse englobant tous les aspects de l'activité bancaire.

Par conséquent, afin de garantir la stabilité du système bancaire, les autorités de supervision ont mis en place des mesures visant à renforcer la gestion et le contrôle des risques, ainsi qu'à établir des normes réglementaires. Ces réformes ont pour objectif d'améliorer les procédures de gestion des risques et de répondre aux exigences de conformité réglementaire.

1. La réglementation internationale du risque de crédit

La réglementation internationale du risque de crédit joue un rôle crucial dans la stabilité du système financier mondial. Ces réglementations visent à renforcer la résilience des banques, à promouvoir des pratiques de gestion des risques plus rigoureuses et à améliorer la transparence des informations financières.

1.1 La réglementation Bâle I

En Juillet 1988, le Comité de Bâle sur le Contrôle Bancaire a publié un rapport visant à promouvoir une harmonisation internationale de la réglementation bancaire, en particulier en ce qui concerne les fonds propres des banques internationales. Cet accord, connu sous le nom de Ratio Cooke en référence au Président du Comité de Bâle à l'époque, a introduit un ratio de solvabilité comme mesure de la stabilité financière des banques. Il a été élaboré en collaboration avec les représentants du groupe des 10 pays les plus industrialisés.

Dans un contexte marqué par l'instabilité financière, la fragilité du système bancaire, la diversification des activités bancaires et l'intensification de la concurrence, il est devenu essentiel de mettre en place un accord international établissant un niveau minimum de fonds propres. Cet accord vise à renforcer la résilience des banques en leur imposant des exigences en termes de capital, afin de prévenir les risques systémiques et de garantir la stabilité financière à l'échelle mondiale.

L'objectif principal de cet accord est d'améliorer la stabilité du système financier international en introduisant des exigences de fonds propres applicables à toutes les banques. Son objectif ultime est de réduire de manière significative le risque d'insolvabilité et de minimiser les coûts que les investisseurs et les contribuables devraient assumer en cas de défaillance bancaire. Des

nombreux pays ont intégré les principes de l'Accord de Bâle I dans leur législation, en les adaptant selon leurs besoins spécifiques, ce qui est considéré comme une réussite.

- **Le ratio Cooke** : en 1988, le premier ratio, connu sous le nom de Ratio de Bâle I ou Ratio Cooke, a été introduit. Ce ratio était calculé en comparant les engagements d'une banque (crédits et autres placements) avec le montant de ses fonds propres (capital apporté par les actionnaires et les bénéfices de la banque). Il était fixé à 8%. Par conséquent, la formule du Ratio Cooke était la suivante :

$$\text{Ratio Cooke} = \frac{\text{Total des Fonds Propres}}{\text{Risque du Crédit}} \geq 8\%$$

- **Les pondérations des éléments du bilan** : varient en fonction du type de créance et du débiteur, ainsi les pondérations des engagements risqués sont les suivants :

0% pour les créances sur les États membres de l'OCDE

20% pour les créances sur les banques ou collectivités locales États membres de l'OCDE

50% pour les créances à garanties hypothécaires

100% pour toutes les autres créances.

- **Pour les engagements d'hors bilan** : on peut distinguer deux types de pondérations :

Pour les engagements classiques non liés au cours de change et au taux d'intérêt, la pondération se fait en convertissant l'engagement en équivalent crédit à l'aide d'un coefficient de conversion variant de 0 à 100 % en fonction de leur nature, puis en les pondérant selon le statut de la contrepartie.

Pour les engagements liés au cours de change et/ou au taux d'intérêt, l'équivalent risque est calculé comme la somme du coût de remplacement total des contrats représentant un gain, ainsi que du risque de crédit potentiel qui est obtenu en multipliant le nominal par un coefficient de majoration dépendant de la durée résiduelle et de la nature du contrat.

Face à l'évolution complexe des techniques bancaires et à la nécessité de prendre en compte des approches plus qualitatives, la norme Cooke a été critiquée pour son manque de considération envers d'autres types de risques tels que le risque de marché, le risque opérationnel, le risque de liquidité, etc. De plus, la norme se concentrait principalement sur les valeurs comptables des actifs plutôt que sur les valeurs de marché, ce qui a révélé ses limites.

1.2 La réglementation Bâle II

L'objectif de la réforme Bâle II est de prendre en compte la complexité croissante de l'activité bancaire tout en permettant aux établissements financiers de choisir parmi différentes options pour déterminer le niveau minimal de fonds propres requis pour couvrir les pertes potentielles. Cette réforme vise à apporter davantage de flexibilité et d'autonomie aux banques dans la gestion de leurs risques, tout en renforçant la stabilité du système financier voir (Nouy, 2003).

L'approche Bâle II marque un changement significatif en passant d'une approche purement quantitative à une approche plus probabiliste et qualitative, où les banques sont tenues d'identifier et de gérer plus efficacement leurs risques. Ce nouveau dispositif permet aux établissements financiers de choisir parmi plusieurs méthodes de calcul des exigences en fonds propres, encourageant ainsi l'utilisation des modèles internes des banques pour une meilleure évaluation des risques. Les banques qui démontrent une capacité solide à gérer leurs risques à l'aide de leurs propres modèles internes bénéficieront de niveaux d'exigences réglementaires en capital plus faibles en récompense.

Le nouvel accord prudentiel, connu sous le nom de Bâle II, vise à améliorer l'évaluation des risques bancaires et à mettre en place un dispositif de surveillance prudentielle et de transparence. Il est entré en vigueur à la fin de l'année 2007 et repose sur trois piliers complémentaires et interdépendants : les exigences minimales de fonds propres, la surveillance exercée par les Autorités prudentielles pour s'assurer de l'adéquation des fonds propres, ainsi que la transparence et la discipline du marché. Ce nouvel accord vise à renforcer la stabilité du système bancaire en encourageant les banques à adopter des pratiques de gestion des risques plus rigoureuses et à améliorer la communication d'informations claires et fiables aux investisseurs et au public.

1.2.1 Pilier I : exigences minimales en fonds propres

Le nouveau ratio de solvabilité, appelé "ratio Mac Donough" dans le cadre des accords de Bâle II, prend en considération les différents risques auxquels une banque est exposée, notamment risque de crédit, risque de marché et risque opérationnel. Contrairement au ratio de Cooke, qui ne prend en compte que le risque de crédit, ce nouveau ratio vise à mieux évaluer la solvabilité d'une banque en prenant en compte l'ensemble de ses risques. La formule exacte de ce ratio peut varier en fonction des méthodes de calcul spécifiques utilisées par les établissements financiers pour mesurer et gérer ces risques.

$$\text{Ratio Mc Donough} = \frac{\text{Fond Propre Réglementaire}}{\text{Risque de crédit} + \text{Risque de marché} + \text{Risque opérationnel}} \geq 8\%$$

Bâle II, se distingue de Bâle I par sa prise en compte d'une gamme plus large de risques et par la flexibilité offerte aux banques dans le calcul des exigences en fonds propres. Concrètement, les banques ont la possibilité d'utiliser différentes approches de pondération des risques pour le risque opérationnel et le risque de crédit. Cela peut inclure des pondérations forfaitaires basées sur la qualité de la contrepartie ou l'utilisation de notations internes. Cette approche permet une meilleure adaptation aux spécificités des banques et favorise une évaluation plus précise de leurs risques.

1.2.2 Le pilier II : processus de surveillance prudentielle

Le pilier II de Bâle II complète et renforce le pilier I en incluant l'analyse des risques globaux de la banque, y compris ceux déjà couverts par le pilier I. Il implique que la banque calcule ses besoins en fonds propres en fonction du capital économique et que le superviseur bancaire compare son évaluation du profil de risque de la banque à celle de la banque elle-même. Cette confrontation permet au superviseur d'adapter ses mesures de surveillance prudentielle, telles que l'exigence de fonds propres supérieurs aux exigences minimales.

1.2.3 Le pilier III : discipline du marché

Le troisième pilier de Bâle II a pour objectif de promouvoir la transparence et la communication financière des banques en les obligeant à fournir des informations fiables et régulières sur leur situation et leurs opérations. Cela permet au marché d'évaluer correctement l'exposition aux risques des banques ainsi que leurs capacités en termes de fonds propres pour y faire face. Ce pilier vise également à permettre aux investisseurs de mieux comprendre les profils de risque des banques, ainsi que la gestion et la couverture de ces risques.

En effet, la crise des subprimes qui a éclaté dès l'été 2007 aux États-Unis a pris une ampleur mondiale et a eu des répercussions majeures sur le secteur bancaire. Cela a remis en question la pertinence et l'efficacité du dispositif Bâle II, qui était sur le point d'être mis en œuvre. Dans ce contexte, le Comité de Bâle a rapidement réagi et a commencé à travailler sur un nouveau dispositif, connu sous le nom de Bâle III, afin de prendre en compte les leçons de la crise et de renforcer davantage la réglementation et la supervision bancaire.

Tableau 1 : La réglementation Bâle II

Pilier 1 : Exigence de fonds propres	Pilier 2 : Processus de surveillance	Pilier 3 : Discipline de marché
Risques de marché Risques de crédit Risques opérationnels	Contrôle des procédures et des méthodes internes d'allocation des FP	Règles de publication financière sur la structure des FP et des risques

Source : Nouy 2003, réforme de Bâle II

1.3 La réglementation Bâle III

En effet, les lignes directrices de Bâle III ont été publiées en décembre 2010 dans le but d'améliorer la capacité des banques à faire face aux conditions économiques et financières, et de renforcer le cadre réglementaire déjà établi par Bâle I et Bâle II. Bâle III poursuit les efforts du Comité de Bâle sur le contrôle bancaire en visant à renforcer la gestion des risques, à améliorer la résilience du secteur bancaire face aux chocs économiques et à promouvoir la transparence des banques. Le dispositif Bâle III conserve la structure à trois piliers, qui se complètent mutuellement.

Selon (Comité de Bâle sur le contrôle bancaire, 2010) ce nouvel accord, basé sur plusieurs objectifs, comprend les éléments suivants :

- Améliorer la qualité des fonds propres des banques pour renforcer leur capacité à faire face aux pertes et à maintenir leurs activités.
- Accroître la couverture des risques liés aux activités de négociation, aux opérations de titrisation, aux expositions hors bilan et aux instruments dérivés.
- Relever les exigences minimales en matière de fonds propres, en particulier pour la composante solide des fonds propres de base, et introduire un volant de conservation pour renforcer les exigences globales.
- Établir un ratio de levier harmonisé au niveau international pour limiter l'accumulation excessive d'endettement dans le secteur bancaire.
- Renforcer les normes de surveillance prudentielle, de communication financière, d'évaluation, de tests de résilience, de gestion des risques de liquidité et de gouvernance.
- Établir des normes internationales minimales de liquidité, y compris un ratio de couverture de liquidité à court terme et un ratio de financement stable net à long terme.

- Encourager les banques à constituer des réserves de fonds propres pendant les périodes favorables afin de les mobiliser en cas de détérioration de la situation économique, y compris un volant de conservation et un volant contracyclique pour atténuer les fluctuations excessives du crédit.

2. La réglementation prudentielle en Tunisie

La Banque Centrale de Tunisie est responsable de l'élaboration de la réglementation prudentielle nationale pour la gestion des risques de crédit. Elle a établi une circulaire principale, la n° 91-24 du 17 décembre 1991, qui a été modifiée le 29 juin 2012 par la circulaire n° 2012-09.

Cette circulaire contient des directives et des normes que tous les établissements de crédit en Tunisie doivent suivre concernant la division et la couverture des risques, la classification des actifs bancaires et la constitution des provisions.

En plus de la circulaire n° 91-24 modifiée par la circulaire n° 2012-09, la BCT a également émis la circulaire n° 16-06 le 11 octobre 2016, qui concerne le système de notation des contreparties, ainsi que la circulaire n° 2020-01 du 29 janvier 2020, qui porte sur les mesures préliminaires à la mise en place des normes internationales d'information financière (IFRS) pour les banques et institutions financières.

2.1 Division des risques

La circulaire n° 91-24 mise en place par la banque centrale vise à atténuer les pertes potentielles en cas de défaut et à répartir l'exposition des établissements de crédit au risque de contrepartie. Selon le premier article de cette circulaire, le montant total des risques encourus ne doit pas dépasser les seuils suivants :

- Pour les bénéficiaires dont le risque encouru est supérieur ou égal à 5% des fonds propres nets (FP nets) de la banque, le montant total des risques ne doit pas dépasser 3 fois les FP nets bancaires.
- Pour les bénéficiaires dont le risque encouru est supérieur à 15% des fonds propres nets, le montant total des risques ne doit pas dépasser 1,5 fois les FP nets bancaires.

De plus, selon le deuxième article de la même circulaire, la banque centrale limite la valeur maximale des risques encourus sur un même bénéficiaire à 25% des fonds propres nets de la banque.

Conformément à l'article 23 de la loi n°2001-65 sur les établissements de crédit, le montant total des risques encourus sur les personnes liées à la banque ne doit pas dépasser 25% des fonds propres nets. Ces personnes doivent être identifiées par le système de mesure de risque de la banque.

2.2 Couverture des risques

Selon l'article 6 de la circulaire n°91-24, le ratio de solvabilité bancaire doit être d'au moins 8%. Cela signifie que les fonds propres nets de chaque établissement de crédit ne doivent pas représenter moins de 8% de leur total d'actifs, du bilan et de l'hors-bilan, pondérés en fonction des risques.

2.3 Classification des actifs

Depuis 1991, tous les établissements de crédit sont tenus de procéder régulièrement à la classification de leurs actifs afin de déterminer le montant des provisions nécessaires pour couvrir les risques encourus. Cette procédure s'applique à tous les types d'actifs, qu'ils soient inscrits au bilan ou hors-bilan, et qu'ils soient libellés en dinars ou en devises. Cependant, il convient de noter que les actifs détenus directement par l'établissement de crédit envers l'Etat ou la BCT ne sont pas soumis à cette classification, car ils représentent un risque souverain.

Selon la circulaire n° 91-24 du 17 décembre 1991, il existe cinq grandes catégories d'actifs, voici une présentation de ces catégories :

- **Classe 0** : il s'agit des actifs sains, cette catégorie englobe les actifs détenus sur des entreprises dont la situation financière est solide ou ne suscite pas de préoccupations majeures.
- **Classe 1** : il s'agit des actifs nécessitant un suivi particulier, cette classe regroupe les actifs détenus sur des entreprises qui respectent leurs engagements financiers à leur échéance, mais qui connaissent une détérioration de leur situation financière ou qui opèrent dans un secteur d'activité en difficulté.
- **Classe 2** : concerne les actifs incertains, cette classe englobe les actifs détenus sur des entreprises qui présentent un retard de paiement des intérêts ou du principal compris entre 90 jours et 180 jours, ainsi que sur des entreprises présentant des éléments préoccupants.

- **Classe 3** : il s'agit des actifs préoccupants, cette classe concerne les actifs détenus sur des entreprises qui ont un retard de paiement des intérêts ou du principal dans la plage de 180 à 360 jours, ainsi que sur des entreprises en difficulté sérieuse.
- **Classe 4** : pour les actifs compromis, cette classe englobe les actifs détenus sur des entreprises dont le retard de paiement des intérêts ou du principal dépasse 360 jours, ainsi que les actifs restés en suspens pendant plus de 360 jours. Elle inclut également les autres actifs qui doivent être considérés comme des pertes après que la banque ait épuisé toutes les procédures légales visant à récupérer ces actifs.

Conclusion

Parmi les différents risques liés à l'activité bancaire, tels que le risque de marché, le risque opérationnel, le risque de liquidité, le risque pays, le risque d'insolvabilité, le risque systémique et le risque de crédit, ce dernier est considéré comme le risque principal auquel une institution bancaire est exposée. Une mauvaise gestion du risque de crédit peut avoir des conséquences désastreuses pour la banque.

Effectivement, compte tenu des conséquences potentiellement néfastes du risque de crédit, les banques doivent veiller à bien maîtriser les risques qu'elles prennent vis-à-vis de leurs contreparties. Pour ce faire, une première étape essentielle consiste à évaluer ce risque de manière approfondie afin de pouvoir le gérer de manière optimale. Dans le prochain chapitre, nous explorerons en détail les différentes méthodes et pratiques de gestion du risque de crédit.

Dans ce chapitre, nous avons abordé les différents types de risques bancaires, en mettant en évidence le risque de crédit. Nous avons également souligné l'importance pour les banques de maîtriser ce risque en l'évaluant de manière approfondie et en le gérant efficacement. De plus, nous avons examiné l'évolution de la réglementation prudentielle de Bâle, qui a influencé les réglementations actuelles en Tunisie. Cette réglementation incite les banques à évaluer et gérer le risque de crédit afin d'assurer une activité bancaire saine et stable.

CHAPITRE 2 : LE STRESS TEST ET GESTION DES RISQUES

CHAPITRE 2 : LE STRESS TEST ET GESTION DES RISQUES

Introduction

Après la crise financière de 2007-2008, les superviseurs et les institutions financières ont de plus en plus utilisé les stress tests pour évaluer les risques bancaires et renforcer les exigences de solvabilité et de liquidité. Ces tests mesurent l'impact des différents risques auxquels les banques sont exposées et évaluent leur capacité à résister à des conditions économiques et financières extrêmes mais plausibles. Les stress tests, également connus sous le nom de tests de résilience bancaire, peuvent être réalisés par les banques centrales ou par les banques individuellement.

Ce chapitre est divisé en trois sections. Dans la première section, nous aborderons l'historique du stress test, sa définition et son objectif. La deuxième section portera sur les différents types, méthodes et approches utilisés pour effectuer les stress tests. Enfin, dans la dernière section, nous nous concentrerons sur les procédures à mettre en place pour réaliser des stress tests, en mettant l'accent sur le stress test du risque de crédit.

Section 1 : Introduction aux stress tests

Les stress tests sont fréquemment utilisés par les établissements financiers pour évaluer quantitativement les pertes ou les risques potentiels dans des circonstances souvent extrêmes. Dans cette section, nous débiterons par un bref historique de l'évolution des stress tests, puis nous présenterons leur définition et leurs objectifs.

1. L'évolution des stress tests

Les premières utilisations des stress tests remontent au début des années 90, principalement pour la gestion interne des risques par les banques individuelles. Au fil du temps, la conception et les fonctions de ces tests ont connu une évolution significative. Avant la crise financière mondiale, la plupart des exercices étaient de petite envergure et servaient à compléter d'autres outils statistiques déjà disponibles au niveau de la direction bancaire pour évaluer les activités commerciales d'une banque voir (Blaschke, Jones, Majnoni, & Peria, 2001). Cependant, l'importance des stress tests s'est accrue, avec des améliorations plus détaillées introduites par l'amendement de 1996 et l'extension aux risques de marché dans l'accord sur les fonds propres (Basel Committee on Banking Supervision, 2009).

De plus, en 2004, dans le cadre de Bâle II, les banques ont été encouragées à mettre en place des exercices de stress tests internes rigoureux, tant pour le pilier I que pour le pilier II. Cependant, Bâle II n'a pas été universellement mis en œuvre, et la plupart des modèles de stress tests internes étaient encore en phase de développement.

Pendant la crise financière mondiale, une attention croissante a été portée sur les tests de résilience, et notamment aux États-Unis et dans l'Union européenne, les autorités ont utilisé des tests de résilience dans leur réponse à la crise. Cette crise financière a mis en évidence les conséquences graves sur l'économie lorsque les banques rencontrent des difficultés et restreignent les prêts, révélant ainsi les lacunes dans la gestion des risques à l'échelle du système financier.

Aux États-Unis, le Supervisory Capital Assessment Program (SCAP) de la Réserve fédérale américaine a été mis en place en 2009 pour évaluer si les principales banques nationales disposaient de suffisamment de capital pour absorber les pertes et continuer à fonctionner. Les résultats ont été rendus publics, et le Département du Trésor américain a fourni une garantie de

soutien. Cet exercice a été évalué comme ayant contribué à restaurer la confiance des marchés et à stabiliser le système financier dans son ensemble voir (Schuermann, 2014).

Dans l'Union européenne, le Comité européen des contrôleurs bancaires (CEBS) a effectué des tests de résilience à partir de 2009. En particulier, en 2010, le CEBS a mené un exercice à l'échelle de l'UE avec une divulgation complète de l'impact estimé sur le capital de chaque banque et de leur exposition au risque, permettant ainsi une comparaison entre ces deux exercices de crise.

Ces tests de résilience ont joué un rôle essentiel pour évaluer la solidité des banques et contribuer à rétablir la confiance des marchés pendant une période critique de la crise financière mondiale.

Dans le domaine réglementaire, le Comité de Bâle sur le contrôle bancaire (CEBS) a étudié les pratiques et publié des principes pour des tests de résilience solides dès 2009, en les mettant à jour en 2018 voir (Basel Committee on Banking Supervision, 2018). La communauté officielle a également encouragé l'intégration d'une dimension macroprudentielle dans les tests de résilience, et il existe désormais une littérature en plein essor qui documente les progrès dans cette direction tel que (Dimitri, 2015). Les autorités nationales ou régionales chargées des tests de résilience microprudentiels et macroprudentiels ont également documenté leurs approches et leur évolution au fil du temps.

2. Définition de stress test

Les tests de résilience sont un outil de gestion des risques largement utilisé pour évaluer l'impact potentiel d'événements spécifiques ou de mouvements dans un ensemble de variables financières sur les établissements financiers. Selon (Paul, Matthew, & Graham, 2004) ces tests évaluent la sensibilité d'un portefeuille à un choc donné en mesurant les variations de sa valeur sous l'effet des changements dans les facteurs de risques sous-jacents. Les hypothèses formulées pour ces tests sont généralement suffisamment importantes pour soumettre le portefeuille à des tensions exceptionnelles, mais elles restent réalistes et plausibles.

Selon (Comité de Bâle sur le contrôle bancaire, 2010), les tests de résilience sont des instruments utilisés par les banques pour la gestion des risques en interne. Ils permettent également aux autorités de mesurer les effets potentiels que des chocs négatifs graves mais plausibles pourraient avoir sur le niveau de fonds propres des établissements bancaires. Ces

tests jouent un rôle essentiel dans l'évaluation de la capacité des banques à faire face à des situations de stress financiers et à s'assurer de leur solidité face aux risques importants.

Le stress test bancaire, ou Stress Testing, sert à évaluer la résilience d'un établissement financier, c'est-à-dire sa capacité à faire face aux situations difficiles. Il permet également de déterminer les pertes potentielles en cas de chocs macroéconomiques inhabituels mais plausibles.

3. Les objectifs des stress tests bancaires

Les cadres de simulation de crise doivent être élaborés afin d'atteindre des objectifs bien définis, qui sont documentés et approuvés au niveau du conseil d'administration de l'organisation ou d'une instance de gouvernance appropriée de niveau supérieur. Ces objectifs doivent être en harmonie avec le cadre de gestion des risques de la banque ou de l'autorité de surveillance, ainsi qu'avec ses structures de gouvernance.

L'utilisation des stress tests internes dans les banques permet d'évaluer la résilience du portefeuille face à des pertes sévères, d'identifier des stratégies appropriées pour réduire les expositions, optimiser les revenus et protéger le capital.

Les objectifs des stress tests pour les autorités de supervision bancaire sont les suivants : évaluer l'adéquation du niveau de capital ou de liquidité des banques sous surveillance, promouvoir les tests de résilience et évaluer la capacité de gestion des risques propres aux banques, soutenir d'autres activités de surveillance telles que les inspections sur place, fournir une évaluation quantitative des profils de risque des banques, tant au niveau individuel que pour l'ensemble du système bancaire.

3.1. Structure de gouvernance et stress tests

Les cadres de stress tests devraient inclure une structure de gouvernance efficace, claire, complète et documentée. Cette structure doit définir les rôles et les responsabilités de la haute direction, des organes de surveillance et des personnes chargées de superviser le fonctionnement continu du cadre de simulation de crise. La gouvernance doit également identifier toutes les parties prenantes clés et garantir une surveillance et un suivi exhaustifs et cohérents des mesures prises à chaque étape du processus de simulation de crise d'après (Basel Committee on Banking Supervision, 2018).

3.2. Gestion des risques et stress tests

Les stress tests sont considérés comme un outil efficace pour améliorer la gestion des risques en raison de leur flexibilité et de la manière dont ils relient explicitement les impacts potentiels à des événements spécifiques. Ils permettent de déterminer comment un portefeuille se comportera pendant une période de crise financière, ce qui en fait l'une des parties importantes du processus de gestion intégrée des risques.

L'émergence des stress tests est en grande partie liée à l'introduction de l'application de modèles dans la gestion des risques bancaires. Ces modèles représentent une simplification de la réalité et permettent de mesurer les risques sous certaines hypothèses spécifiques. Cependant, les conditions réelles du marché peuvent inclure des scénarios extrêmes et exceptionnels que ces modèles et leurs hypothèses ne peuvent pas prendre en compte. Ainsi, l'objectif principal des tests de résilience est d'analyser de telles lacunes dans la gestion des risques bancaires voir (Ličák, 2016).

4. Value at Risk et Stress test

Parmi les méthodes les plus utilisées pour quantifier les risques bancaires se trouvent la VaR (Value at Risk) et le Stress Testing, qui sont couramment employées. La VaR est un outil de gestion des risques apprécié pour sa simplicité et sa flexibilité, adopté progressivement par les institutions financières depuis les années 90. Cependant, des erreurs fréquentes de gestion, notamment en période de crise, ont été constatées lors de son utilisation. Pour faire face aux risques extrêmes, les premiers stress tests ont été développés. Plusieurs critiques sont adressées à l'utilisation de la VaR dans la gestion des risques, notamment le caractère subjectif du choix des paramètres tels que le niveau de confiance et l'horizon de détention. De plus, la VaR manque de précision pour les pertes extrêmes au-delà du niveau de confiance considéré, ne fournissant pas d'informations sur leur taille ni leur nature.

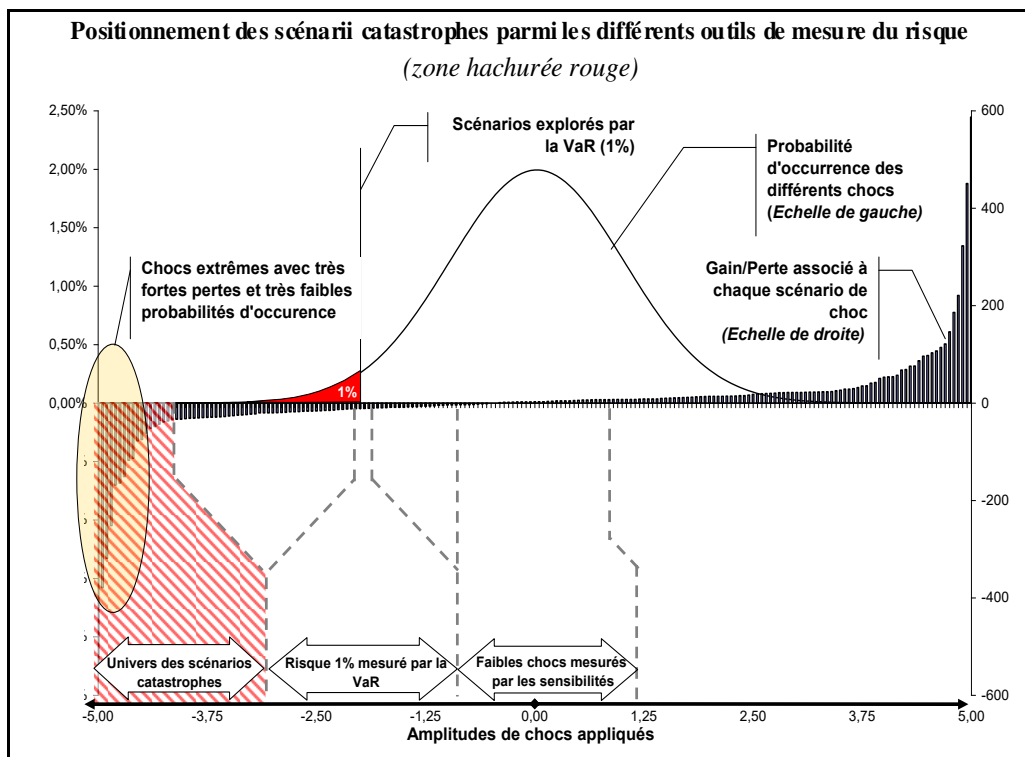
Cependant, les stress tests ont apporté deux innovations majeures voir (Committee on the Global Financial System, 2005) :

- Ils explorent plus en profondeur les queues de la fonction de distribution de la valeur du portefeuille au-delà des niveaux de confiance couramment utilisés dans la VaR.
- Ils établissent un lien flexible et explicite entre les pertes extrêmes potentielles de la valeur du portefeuille et les événements sous-jacents, c'est-à-dire les scénarios de stress.

Cela permet d'identifier profondément et explicitement les sources de risque, contrairement à l'approche purement statistique de la VaR. Grâce à cette technique, il est possible de mesurer la contribution de chaque facteur de risque, dans chaque scénario, à l'évolution potentielle de la valeur du portefeuille.

Les stress tests fournissent des informations sur les risques qui ne font pas partie de ceux généralement pris en compte par le cadre de la VaR. En conséquence, ils permettent de mettre en évidence des risques associés à des mouvements de prix extrêmes et à des scénarios prospectifs qui ne sont pas reflétés dans l'historique récent des séries de prix utilisées pour calculer la VaR.

Figure 1 : Intégration du stress test dans la VaR



Source : Committee on the Global Financial System. (2005).

Section 2 : Classification, méthodologies et modèles de stress tests

Dans cette section, nous examinerons en détail les diverses catégories de stress tests, les approches utilisées pour les réaliser, ainsi que les modèles et méthodologies employés dans le processus de stress testing.

1. Les types des stress tests

Les tests de résilience sont généralement classés en deux catégories distinctes : les tests de sensibilité et les tests de scénario.

1.1. Test de sensibilité

Les tests de sensibilité consistent généralement à apporter des changements progressifs à un ou à quelques facteurs de risque afin de fournir des réponses aux questions de simulation. Ils sont généralement réalisés sur une période plus courte, comme un choc instantané. Comparés aux tests de scénario, les tests de sensibilité requièrent moins de ressources et peuvent être utilisés comme une approche plus simple pour évaluer l'impact des changements de risque lorsque des résultats rapides ou des évaluations fréquentes sont nécessaires voir BSIF (2009).

1.2. Tests de scénarios

Exactement, les tests de résilience de scénarios évaluent l'effet des changements simultanés d'un ensemble de variables constituant un scénario exceptionnel mais plausible. Ces scénarios de stress tests doivent prendre en considération plusieurs événements avec différents degrés de gravité. Cette approche présente l'avantage de prendre en compte les effets et les interactions entre plusieurs variables qui influencent le modèle, ce qui n'est pas possible lorsque seulement un facteur de risque est soumis à un choc. Les tests de résilience de scénarios permettent ainsi d'avoir une vision plus réaliste des risques potentiels et de mieux comprendre comment une combinaison d'événements extrêmes pourrait affecter la solidité et la résilience d'une institution financière.

1.2.1. Les types de scénarios stress tests

En général, il existe deux types de scénarios générés dans un stress test selon (Moussaoui, 2015):

- **Scénario de base** : C'est un scénario sans stress qui suppose que la situation de l'établissement en question suivra la même évolution dans le futur et qu'il n'y aura pas de chocs prévus à l'avenir. Ce scénario sert de référence pour évaluer la performance de l'établissement dans des conditions normales.
- **Scénario adverse** : C'est un scénario, également appelé scénario extrême, dans lequel il est supposé que l'établissement en question soit confronté à un choc extrême dans l'avenir, mettant ainsi sa stabilité financière en péril. Ce scénario permet d'évaluer la résilience de l'établissement face à des conditions économiques et financières difficiles.

1.2.2. La conception des scénarios stress tests

La conception d'un scénario de stress implique de définir quantitativement :

- **La taille du choc initial** : C'est l'ampleur du changement qui sera appliqué par simulation aux facteurs de risque.
- **La manière dont les changements sont appliqués et évoluent au fil du temps** : Ce sont les variations des facteurs de risque qui persistent et interagissent tout au long de l'horizon du test, ce que l'on appelle "le post choc".
- **Les probabilités d'occurrence correspondantes** : Il s'agit des probabilités associées à la réalisation du scénario, c'est-à-dire la probabilité que les événements stressants se produisent.

Ces trois composantes, à savoir la taille du choc initial, les variations post-choc des facteurs de risque et les probabilités d'occurrence, sont essentielles pour la création et l'évaluation d'un scénario de stress test.

1.3. Approche du stress test inversé

Les établissements utilisent l'approche du stress test inversé qui consiste à commencer par l'identification du résultat souhaité, puis à explorer les scénarios et les circonstances susceptibles de mener à cette situation. Cette approche est utilisée comme un outil de gestion des risques pour améliorer la prise de conscience des vulnérabilités actuelles et potentielles. Les établissements utilisent ces tests pour évaluer la viabilité et la durabilité de leurs modèles.

Ainsi les étapes du stress test se déroulent comme suit :

- Le choix du périmètre du stress test et la détermination de l'hypothèse de crise permettent de définir les paramètres spécifiques du test, tels que le coefficient de

solvabilité en dessous de la limite réglementaire, afin d'évaluer la résilience de l'établissement face à des situations de crise potentielles de manière réaliste et pertinente.

- Pour déterminer le couple (PD, LGD) responsable d'un choc spécifique dans un stress test, il faut identifier le choc, définir l'hypothèse de crise, collecter les données historiques sur les défauts et les pertes, puis réaliser une analyse quantitative pour évaluer son impact.
- Une analyse quantitative avec des modèles établit les liens entre les variables macroéconomiques, la probabilité de défaut (PD) et la perte en cas de défaut (LGD), aidant ainsi à comprendre l'influence des conditions économiques sur les risques de défaut et les pertes.
- Une analyse d'experts (économistes) évalue les résultats du modèle pour choisir les variables économiques responsables du choc dans les stress tests.

2. Les approches de Stress Test

Les modèles de stress test se basent sur deux approches principales pour définir les événements à tester : les scénarios historiques et les scénarios hypothétiques.

- **Scénarios historiques (méthodes objectives) :** Ces approches utilisent des événements réels qui se sont produits dans le passé, tels que des crises financières ou des périodes de turbulence économique. En se basant sur ces événements passés, les stress tests peuvent évaluer la résilience du portefeuille en simulant des situations de marché réelles et tendues, avec moins de jugements subjectifs.
- **Scénarios hypothétiques (méthodes subjectives) :** Ces approches se concentrent sur des événements potentiels ou des situations extrêmes qui n'ont pas encore eu lieu, mais qui pourraient survenir à l'avenir. Les scénarios hypothétiques permettent d'explorer des risques spécifiques qui pourraient ne pas être reflétés dans les événements passés, offrant ainsi une évaluation plus complète des vulnérabilités du portefeuille.

En pratique, les stress tests peuvent combiner ces deux approches pour créer des scénarios hybrides, utilisant à la fois des événements historiques pour calibrer certains aspects du test, et des éléments hypothétiques pour évaluer des risques émergents ou inédits. Cette approche mixte permet de mieux évaluer la robustesse du portefeuille face à un large éventail de risques potentiels.

3. Les modèles de stress test

Les stress tests sont des outils d'évaluation de la résilience des banques face à des chocs potentiels d'ordre microéconomique ou macroéconomique. Ils peuvent être appliqués à l'échelle des institutions financières individuelles, appelée stress test micro prudentiel, ou à celle du système financier dans son ensemble, connu sous le nom de stress test macro prudentiel voir (Mathieu, 2014).

3.1. Les modèles Micro prudentiel

Les tests de résilience microprudentiels, qui sont effectués à l'échelle de chaque banque individuelle, se concentrent étroitement sur les risques spécifiques aux banques. Ils évaluent les expositions au risque à des fins internes pour déterminer si les fonds propres sont adéquats et pour allouer ces fonds de manière appropriée. Ces tests sont également utilisés par les autorités de contrôle pour évaluer la santé des banques et la résilience du secteur bancaire dans son ensemble voir (Taskinsoy, 2013).

Les tests de résilience étaient relativement obscurs au 20^{ème} siècle, mais ils sont devenus familiers au 21^{ème} siècle. La Banque des règlements internationaux (BRI) les définit comme «Diverses techniques utilisées par les institutions financières pour évaluer leur vulnérabilité potentielle face à des situations d'événements exceptionnels mais plausibles».

3.2. Les modèles Macro prudentiel

Les macros stress tests ne fonctionnent pas en tant qu'outil autonome, mais plutôt comme une boîte à outils utilisée par les banques centrales. Ils fournissent des scénarios de crise communs aux différentes institutions, permettant ainsi de tester la solidité financière des banques et des établissements financiers de manière cohérente et comparative.

Dans l'ensemble, les tests de résilience (micro et macro) ont apporté des avantages financiers et sociétaux, car ils ont permis de rassembler divers points de vue pour atteindre un objectif commun : la construction et le maintien d'un système financier mondial résilient, capable de faire face aux chocs, y compris les pires récessions ou dépressions, comme l'induit un stress test.

Il existe deux principales méthodes d'agrégation pour mener les tests de résilience : l'approche ascendante "bottom up" (BU) et l'approche descendante "top down" (TD).

- **Les tests de résilience microprudentiels (BU)** sont réalisés par les grandes banques individuelles pour leur gestion interne des risques et par les superviseurs pour évaluer leur solvabilité selon le pilier II de Bâle II et III, en utilisant des analyses de sensibilité et des scénarios.
- **Les tests de résilience macroprudentiels (TD, ou une combinaison de BU et TD)** sont menés par les banques centrales et les autorités de contrôle pour évaluer la stabilité de l'ensemble du système financier, ainsi que pour la surveillance au niveau national et international.

Ces approches permettent d'évaluer la résilience du système financier dans son ensemble et de prendre des mesures pour améliorer sa capacité à faire face à des situations de stress et de crise.

L'approche "Bottom-up" permet aux autorités réglementaires d'appliquer un modèle commun à différentes banques, ce qui leur permet de comparer les résultats entre les banques afin d'identifier les vulnérabilités liées à des chocs similaires. Cette méthode permet d'évaluer la résilience des banques individuelles et de comprendre comment elles réagiraient face à des scénarios de stress communs, ce qui contribue à renforcer la stabilité du système financier dans son ensemble.

L'approche "Top-down" dans les tests de résilience permet aux banques individuelles d'utiliser leurs modèles internes. Le principal avantage de cette approche est que les modèles internes des banques capturent les spécificités de chaque établissement, ce qui permet de mieux comprendre les facteurs spécifiques qui influencent les résultats pour chaque banque. Cette méthode offre une meilleure prise en compte des caractéristiques propres à chaque institution, ce qui peut améliorer la pertinence et la précision des résultats du test de résilience voir (Anand, Guillaume, & Virginie, 2014).

Tableau 2 : Types des modèles de stress test

Typologie	Utilisation	Avantages	Inconvénients
Micro prudentiel Banque individuelle Bottom up	Les banques utilisent leurs propres tests de résilience, tels que des analyses de sensibilité et de scénarios, pour évaluer leurs expositions aux risques.	Les modèles internes évaluent l'adéquation des fonds propres et la résilience des banques.	Les banques utilisent des méthodes de mesure des risques variées, se concentrant soit sur des portefeuilles ciblés, soit sur des facteurs de risque uniques.

<p>Micro prudentiel</p> <p>Superviseurs</p> <p>Top down</p>	<p>Les tests de résilience prudentiels recueillent des données auprès des banques pour évaluer leur solidité financière et s'assurer qu'elles respectent les exigences minimales en termes de fonds propres et de liquidités.</p>	<p>L'amélioration de la gouvernance et de la transparence est un aspect essentiel de la surveillance bancaire pour assurer la stabilité et la confiance dans le secteur financier.</p>	<p>L'amélioration de la gouvernance et de la transparence dans la surveillance bancaire exige des banques des ajustements coûteux et complexes en matière de prêt et de planification du capital.</p>
<p>Macro prudentielle</p> <p>Banque centrale</p> <p>Top down</p>	<p>La planification prévisionnelle des fonds propres vise à assurer que les banques disposent de suffisamment de capitaux propres et de liquidités dans des conditions de marché hautement improbables.</p>	<p>La répartition planifiée du capital consiste à appliquer de manière cohérente plusieurs scénarios à l'échelle du système pour garantir une allocation adéquate des fonds propres.</p>	<p>La répartition planifiée du capital est un processus prévisible mais coûteux, et complexe.</p>
<p>Macro prudentielle</p> <p>FMI, FSAP</p> <p>Bottom up</p> <p>Top down</p>	<p>L'aide fournie aux pays pour renforcer leur résilience aux chocs vise à favoriser la stabilité financière, la croissance et la diversité du secteur financier, en appliquant des mesures cohérentes.</p>	<p>Le coût de l'aide pour renforcer la résilience aux chocs est partagé entre le FMI et la Banque mondiale, et elle est mise en œuvre de manière volontaire, systématique et cohérente.</p>	<p>Les résultats volontaires et trompeurs de l'aide peuvent entraîner une perte de crédibilité, ainsi qu'un gaspillage de ressources et une perte d'efficacité.</p>

Source : Taskinsoy John (2019), Typology of Stress Testing

Section 3 : Mise en place des stress tests : procédures et démarches

Dans cette section, nous abordons les principales étapes et démarches impliquées dans la mise en place des stress tests au sein des institutions financières.

1. Les étapes clés de la mise en place des stress tests

Le processus des tests de résilience comprend plusieurs étapes, telles que :

- **Définition des objectifs** : Les objectifs du stress testing doivent être précisément définis et compréhensibles pour les décideurs, allant au-delà de simples contraintes réglementaires.
- **Définition du périmètre** : Selon les objectifs, le stress test peut être appliqué à l'ensemble de l'établissement ou à un périmètre plus restreint. Un périmètre réduit facilite l'exploitation des résultats mais peut limiter la mesure des corrélations entre activités ou secteurs.
- **Définition des scénarios** : Les chocs appliqués doivent être adaptés à la nature de l'établissement et refléter son aversion au risque. Ils peuvent être de différentes natures, tels que les tests de robustesse des modèles ou les tests de stabilité financière.
- **Choix de la démarche** : Le stress testing peut être effectué selon deux approches : quantitative basée sur des modèles ou qualitative avec l'expertise d'un groupe d'experts.
- **Analyse et décisions** : L'analyse des résultats mettra l'accent sur les tendances dégagées et les niveaux atteints par rapport aux limites et à la perception des risques par les dirigeants. Les décisions qui découlent de ces exercices porteront sur les règles régissant l'activité, comme les plans de contingence et les limites de risques.

2. Mise en œuvre des stress tests de crédit

Les stress tests de crédit suivent une procédure en trois étapes pour évaluer l'impact d'un scénario macroéconomique stressé sur la qualité des expositions de crédit des banques. Tout d'abord, les valeurs prévisionnelles des variables macroéconomiques sont déterminées pour un scénario spécifié et une période donnée. Ensuite, l'impact de ces variations sur les paramètres de risque de crédit des banques, tels que la probabilité de défaut (PD) et la perte en cas de défaut (LGD), est estimé. Enfin, les paramètres de risque de crédit stressés sont utilisés pour évaluer l'incidence du scénario de stress sur la solvabilité des banques.

En pratique, la mise en œuvre des deux premières étapes implique généralement deux types de modélisation distincts. Tout d'abord, pour prédire le comportement des variables macroéconomiques, telles que la croissance du PIB et le taux d'intérêt à long terme, sous un scénario de stress prédéfini et sur une période donnée, on utilise généralement un modèle macro économétrique. Ce modèle intègre des chocs défavorables pour une ou plusieurs variables macroéconomiques, et les équations du modèle déterminent comment ces variables ainsi que d'autres se comportent en réponse à ces chocs sur l'horizon des tests de résilience. Ensuite, une deuxième étape de modélisation est nécessaire pour estimer l'impact des variables macroéconomiques stressées sur les paramètres de risque de crédit des banques à l'horizon des tests de résilience. Ces modèles de risque de crédit consistent principalement en une ou plusieurs équations reliant les paramètres de risque de crédit des banques aux variables macroéconomiques.

Les variables macroéconomiques stressées, dérivées du modèle macro économétrique, sont utilisées comme entrées dans l'équation du modèle de risque de crédit pour obtenir les valeurs stressées des paramètres de risque de crédit. Enfin, ces valeurs stressées des paramètres de risque de crédit sont appliquées aux pertes et aux profits des banques afin d'estimer l'impact sur leur position de solvabilité.

3. Etudes empiriques des stress tests sur le risque de crédit

(Zeman & Jurca, 2008), ont évalué l'impact d'un ralentissement simulé de l'économie slovaque sur le secteur bancaire du pays. À l'aide d'un modèle de correction d'erreurs vectorielles, ils ont constaté que, dans l'ensemble, un ralentissement temporaire mais significatif de la croissance du PIB ne représenterait pas une menace substantielle pour le secteur bancaire slovaque, à condition que la politique monétaire réponde de manière adéquate. Cette politique monétaire aurait un effet positif en atténuant la récession et en améliorant la qualité du portefeuille de crédit grâce à la baisse des taux d'intérêt, ce qui allégerait le fardeau de la dette des emprunteurs à court terme. Cependant, ils ont souligné que l'absence de réponse adéquate aux chocs de croissance du PIB ainsi que les risques de taux de change et de taux d'intérêt pourraient constituer des menaces plus significatives pour le secteur bancaire slovaque en raison de l'ouverture de l'économie du pays.

Dans l'étude de (Ben youcef, 2018), un modèle a été proposé pour réaliser un stress test macro du risque de crédit sur un échantillon de dix banques commerciales tunisiennes. L'approche

utilisée implique d'expliquer le risque de crédit pour chaque banque en utilisant un modèle statistique à effets fixes. Ensuite, un stress test de résilience a été réalisé en utilisant une simulation de Monte Carlo pour générer des distributions de pertes de risque de crédit pour différents scénarios, permettant ainsi de déterminer les pertes inattendues pour chaque banque. Les résultats de l'analyse ont révélé une relation négative entre le risque de crédit et le taux de croissance du PIB, ainsi que le ratio des prêts sur le total des actifs. De plus, le ratio de rendement des actifs et la taille de la banque ont également été identifiés comme ayant un impact négatif sur le risque de crédit. Les résultats du test de résilience ont montré qu'un scénario défavorable de ralentissement économique entraîne une augmentation des pertes de crédit les plus élevées pour toutes les banques de l'échantillon, mais que ces pertes inattendues peuvent être couvertes par le capital disponible des banques concernées.

Dans leur étude, (Onha, Yen, Trang, & Trung, 2018) ont évalué la capacité des banques commerciales vietnamiennes à faire face à une augmentation du risque de crédit à la suite de chocs macroéconomiques. Ils ont utilisé un modèle VAR pour estimer la relation entre les variables macroéconomiques (PIB réel, taux de change réel, taux d'intérêt prêteur et taux d'inflation) et ont établi des scénarios macroéconomiques à partir de ces estimations. Ensuite, ils ont utilisé un modèle GMM pour estimer la relation entre le ratio de prêts non performants (risque de crédit) et les variables macroéconomiques identifiées précédemment. Enfin, le nouveau ratio de capital requis (CAR) a été recalculé en tenant compte de l'augmentation du risque de crédit et de l'augmentation des créances douteuses. Les résultats montrent que le risque de crédit auquel les banques commerciales sont confrontées est relativement limité tant que leurs actifs pondérés en fonction des risques restent inchangés. Cependant, si ces chiffres augmentent à mesure que les banques étendent leurs prêts, le CAR de toutes les banques diminuera considérablement, et certaines des plus grandes banques risqueront de ne pas pouvoir répondre aux exigences de la Banque centrale en matière de capital.

Dans son étude, (Zouali, 2015) a tenté de développer un modèle approprié pour expliquer le risque de défaut au sein de la banque marocaine BMCI en utilisant un modèle VAR. Ce modèle a ensuite été utilisé pour simuler des chocs sur l'ensemble des variables explicatives du risque de crédit afin d'évaluer leur impact sur la solvabilité de la banque. Les résultats du modèle indiquent que les variables PIB, inflation et crédit immobilier sont les plus significatives. L'auteur propose que les fonds propres de la banque BMCI absorbent ces chocs afin de

maintenir un ratio de solvabilité supérieur à 8%. Cependant, il souligne que la crise immobilière a un impact plus prononcé sur les fonds propres de la banque.

Les travaux de (Andrea, Danilo, Nicola, & Tommaso, 2023) se concentrent sur l'utilisation d'un modèle VAR bayésien pour évaluer la suffisance en capital d'une banque à travers des tests de résistance. L'étude vise à analyser les impacts potentiels des chocs macroéconomiques sur la capacité de la banque à maintenir des niveaux adéquats de capitaux réglementaires. En utilisant des techniques statistiques basées sur la théorie VAR bayésienne, l'article explore la relation entre les variables macroéconomiques, les indicateurs de risque et les mesures de capital de la banque. Cela permet d'évaluer la résilience de la banque face à différentes conditions économiques stressantes.

(Jacobs, Ahmet, & Frank, 2015) ont contribué à la littérature en développant une méthodologie de test de résistance au risque de crédit basée sur la méthode bayésienne. Leur travail propose une approche qui peut être mise en œuvre par des banques de petite et moyenne taille, en intégrant formellement des scénarios exogènes et en quantifiant l'incertitude dans les résultats du modèle résultant des entrées du modèle stochastique. Ils ont également comparé leur modèle bayésien à un modèle classique, en mettant en évidence des différences significatives en termes de mesure de l'incertitude statistique et d'erreur cumulée. Les résultats empiriques obtenus à partir des mises en œuvre du CCAR viennent appuyer leur approche. Cette contribution à la littérature renforce la compréhension des tests de résistance et de la validation des modèles dans le contexte de la gestion du risque de crédit.

4. Avantage de l'application de stress tests avec la modélisation BSVAR

La méthode de réalisation des stress tests à l'aide du modèle bayésien présente également des avantages selon plusieurs auteurs :

Selon (Pflug & Pohl, 2018), l'approche bayésienne permet de quantifier l'incertitude liée aux scénarios de stress en utilisant des distributions de probabilité pour les variables clés. Cela permet d'obtenir des résultats plus robustes et de prendre en compte les différentes sources d'incertitude dans les prévisions des pertes potentielles. Ainsi d'après (Giudici & Spelta, 2016), l'approche bayésienne permet d'incorporer des connaissances expertes et des informations supplémentaires dans le processus de modélisation des scénarios de stress. Cela permet d'améliorer la qualité des prévisions en intégrant des informations spécifiques au contexte et en évitant les biais liés à une modélisation purement statistique.

Selon (Gael, et al., 2023), l'approche bayésienne permet de gérer efficacement les données manquantes ou les informations incomplètes dans les scénarios de stress. En utilisant des techniques d'imputation bayésienne, il est possible d'estimer les valeurs manquantes de manière robuste et d'éviter les biais liés à des valeurs manquantes arbitraires. En outre selon (Hegde, Hegde, Marthanda, & Logu, 2023), l'approche bayésienne permet de combiner de manière cohérente les informations provenant de différentes sources, telles que des données historiques, des données expertes et des données économiques, pour construire des scénarios de stress plus réalistes et plus précis. Cela permet d'obtenir des résultats plus fiables et de prendre en compte une plus grande variété de facteurs pertinents.

Enfin, selon (Gary, Dimitris, & Davide, 2019), l'approche bayésienne permet de mettre à jour les scénarios de stress au fur et à mesure que de nouvelles informations deviennent disponibles, ce qui permet de suivre l'évolution de l'environnement économique et d'ajuster les prévisions en conséquence. Cela permet d'obtenir des résultats plus adaptés aux conditions actuelles et de prendre des décisions plus éclairées.

En conclusion, l'utilisation de l'approche bayésienne dans la réalisation des stress tests présente des avantages significatifs, notamment en termes de quantification de l'incertitude, d'intégration de connaissances expertes, de gestion des données manquantes, de combinaison d'informations provenant de différentes sources et de mise à jour des scénarios de stress en fonction des nouvelles informations disponibles.

Conclusion

Dans ce chapitre, nous avons présenté le stress test comme un outil pratique de gestion des risques, visant à quantifier les pertes ou les risques potentiels dans des circonstances particulières, souvent extrêmes. Ces circonstances sont définies par des scénarios issus de l'expérience historique (stress test historique) ou jugés possibles à l'avenir en tenant compte de l'évolution des facteurs macroéconomiques, socioéconomiques ou politiques (stress test hypothétique).

Les modèles de tests de résilience varient d'un établissement à l'autre en fonction de la nature du problème étudié et de la sélection des scénarios de stress. En général, les stress tests jouent deux rôles principaux : d'une part, en tant qu'outil de gestion des risques utilisé par les banques, et d'autre part, en tant qu'instrument de supervision macroprudentielle utilisé par les régulateurs de différents pays, avant même que la crise ne survienne. La flexibilité de pouvoir mettre en œuvre différents tests en fonction du champ d'application, du risque ou du scénario à étudier est un avantage certain.

Enfin, nous avons mis l'accent sur la littérature des différentes études du stress test effectuées, que ce soit au niveau macroprudentiel ou microprudentiel. Ainsi chaque étude montre l'utilisation d'une approche différente mais qui conduit aux mêmes objectifs. Tandis qu'une nouvelle vision du stress test inversé qui est déduit d'une modélisation bayésienne qui présente une multitude des avantages du niveau économétrique et analytique. Ce qui va faire l'objet de notre dernier chapitre qui va développer ses approches pour crée une nouvelle dimension pour modéliser l'intuition de l'état d'esprit des preneurs des décisions.

**CHAPITRE 3 : APPLICATION DU STRESS TEST DE RISQUE
DE CREDIT**

CHAPITRE 3 : APPLICATION DU STRESS TEST DE RISQUE DE CREDIT

Introduction

Dans le premier chapitre, nous avons abordé le risque de crédit et les règles prudentielles au niveau international et national. Dans le deuxième chapitre, nous avons mis en évidence l'importance du stress test en tant qu'outil pour évaluer la résilience d'une banque.

Dans ce chapitre, notre objectif est d'établir un modèle de risque de crédit englobant qui prend en compte à la fois les facteurs spécifiques à la banque et ceux liés à l'environnement macroéconomique. Pour atteindre cet objectif, nous avons commencé par critiquer les approches utilisées dans la plupart des travaux réalisés, et nous nous efforçons à chaque étape de résoudre leurs insuffisances en améliorant la modélisation. Cela nous permettra de parvenir à un cadre complet grâce au modèle BSVAR. En utilisant ce modèle, nous analysons l'impact d'une mauvaise prise de décision résultant de variations de certains facteurs, dans le but d'évaluer le risque de crédit à travers un stress test inversé.

Dans ce chapitre, nous le divisons en trois sections distinctes. La première section est dédiée à la présentation de la BFPME ainsi que de sa direction des risques. Dans la deuxième section, nous débutons en exposant la méthodologie choisie pour notre étude, puis nous procédons à l'estimation des modèles, et nous clôturons notre section par une comparaison visant à vérifier l'importance de l'intégration de l'approche bayésienne. Enfin, la troisième section se concentre sur l'application du stress test inversé sur le modèle établi et l'analyse des résultats obtenus, permettant ainsi d'évaluer l'impact de ces réflexions sur le niveau des NPL de la banque face aux scénarios de stress.

Section 1 : Présentation et organisation de la BFPME

La section suivante sera dédiée à une introduction générale sur la BFPME. Nous commencerons par une brève rétrospective historique de la banque, puis nous aborderons ses missions, ses objectifs et sa stratégie, tout en examinant également la structure de la direction d'accueil et ses responsabilités.

1. Présentation et historique de la BFPME

Au début des années 2000, la Tunisie a ressenti une stagnation de son modèle économique et a décidé de lier sa politique de développement à l'entrepreneuriat. Cette démarche visait à atteindre des objectifs d'inclusion financière et de développement régional, ce qui a conduit à la création de la Banque de Financement des Petites et Moyennes Entreprises (BFPME).

1.1. Historique de la BFPME

La BFPME a été établie le 1er mars 2005 et opère conformément à la loi n°2016-48 du 11 juillet 2016, qui régit les établissements de crédit. Elle est en mesure de soutenir financièrement tous les projets d'investissement des PME, qu'elles soient en phase de création ou d'extension, pour des investissements compris entre 100 mille et 15 millions de TND, couvrant ainsi divers secteurs économiques. À noter que certaines exceptions s'appliquent, notamment dans le secteur du tourisme (si la composante principale est l'hébergement) et de la promotion immobilière (si elle est destinée à l'habitation).

La BFPME intervient en accordant des crédits à moyen et long terme, principalement en cofinancement avec d'autres banques locales, ce qui en fait un acteur central du segment de la mésofinance dédiée aux PME. Elle se positionne entre la microfinance, qui cible les TPE, et la finance bancaire destinée aux grandes entreprises.

1.2. La stratégie de la BFPME

La BFPME assure principalement une double mission, à savoir :

- Fournir un accompagnement aux promoteurs tout au long des diverses étapes de la réalisation de leurs projets, y compris l'identification de l'idée du projet, l'élaboration du business plan, le bouclage du schéma de financement, la création juridique de la société, ainsi que le suivi de la mise en œuvre et du développement de l'activité.

- La BFPME a pour mission de simplifier l'accès au financement pour la création et l'extension des PME en Tunisie. À cette fin, elle est chargée de fournir des crédits à moyen et long terme exclusivement destinés à financer les investissements. De plus, elle joue un rôle de passerelle vers des instruments financiers spécifiques.

Dans le cadre de sa stratégie de développement ambitieuse, visant à moderniser ses structures et ses méthodes de gestion pour aligner la banque sur les normes internationales, la BFPME s'est fixée les objectifs suivants :

- Améliorer la qualité des services et des structures d'accueil.
- Accroître les ressources à des coûts optimisés pour une meilleure rentabilité.
- Moderniser les outils d'intervention et de gestion.
- Mettre en place des mécanismes de contrôle et de suivi efficaces pour garantir la fiabilité des opérations et des données.
- Assurer une meilleure gestion et maîtrise des risques.

2. Présentation de la direction des risques

La direction des risques a pour mission de classer les divers types de risques associés à l'activité de la banque, d'établir les procédures et méthodes pour l'identification, l'analyse, le contrôle et le suivi de ces risques. Elle est également chargée d'évaluer les risques et d'estimer la vulnérabilité de la banque ainsi que de ses performances financières en recourant aux stress tests.

La direction des risques est rattachée au directeur général adjoint en charge du contrôle permanent et est supervisée par un directeur.

Section 2 : Modélisation du risque de crédit

Cette section commence par présenter la méthodologie de recherche ainsi que les variables utilisées. Ensuite, elle passe à l'estimation des modèles de risque de crédit. Enfin, une comparaison sera effectuée pour démontrer l'importance de l'intégration de l'approche bayésienne dans le contexte des modèles de la famille VAR.

1. Méthodologie de recherche

Nous commençons par la présentation et l'analyse technique des modèles VECM et BSVAR, puis la détermination des variables utilisées.

1.1. Présentation du modèle VECM

Depuis la critique formulée par (Sims, 1980), la modélisation Vectorielle Autorégressive (VAR) est devenue un outil standard en économétrie pour l'analyse des séries temporelles multivariées. Grâce à l'utilisation de modèles vectoriels, les chercheurs peuvent examiner simultanément plusieurs variables en interaction.

Depuis la fin des années 80, il est devenu évident que la non-stationnarité est une caractéristique courante des séries temporelles macroéconomiques et financières. En effet, la plupart des séries présentent des tendances non stationnaires. Pour résoudre ce problème, l'économétrie des séries non stationnaires a connu un développement majeur grâce à la théorie de la cointégration, élaborée par (Engle & Granger, 1987), ainsi que par (Johansen, 1988) et (Johansen, 1991). L'attrait croissant de ce concept réside dans sa capacité à permettre l'estimation et la mise à l'épreuve des relations d'équilibre à long terme entre les variables grâce à la modélisation du Vector Error Correction Model (VECM).

1.2. Présentation du modèle BSVAR

La modélisation Structurale Vectorielle Autorégressive (SVAR) est un élargissement de la modélisation VAR. Ce dernier est établi comme une démarche a-théorique, qui se limite à l'étude de la dynamique des variables sans aucune identification théorique. Pour faire face à cette limite, nous soulignons l'apparition des modèles SVAR.

Certes, les modèles SVAR offrent un moyen robuste et pratique pour la modélisation et l'interprétation des chocs externes. Cependant, comme la plupart des modèles économétriques,

le modèle SVAR repose exclusivement sur les informations disponibles dans les données. Cela ne permet pas de tenir compte de l'intuition et des perspectives des responsables et des décideurs, en particulier dans les situations exceptionnelles, telles que les périodes de crises et de chocs économiques majeurs.

Par conséquent, l'approche fréquentiste, qui ne prend pas en compte les éléments non observables, peut limiter l'interprétation. C'est pourquoi l'approche de l'estimation bayésienne a été développée, notamment à travers les modèles BSVAR. Cette approche permet à l'économètre d'incorporer des informations supplémentaires sur les contraintes d'identification ainsi que sur les paramètres du modèle en se basant sur des distributions probabilistes, appelées distributions à priori.

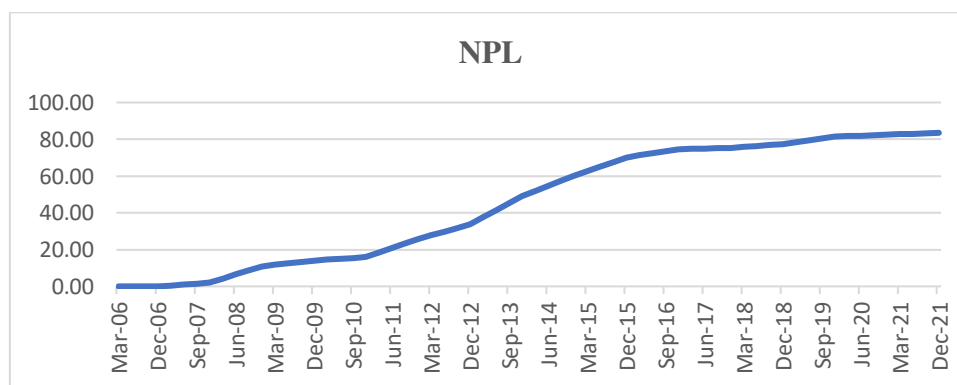
1.3. Présentation des données

Dans le cadre de notre étude visant à estimer le modèle de risque de crédit, nous avons utilisé des données spécifiques à la BFPME obtenues à partir des états financiers publiés sur le site de la CMF, ainsi que des données macroéconomiques provenant des sites de l'INS et de la BCT. Nous avons veillé à rassembler un volume maximal d'observations pour assurer la robustesse de nos modèles. En conséquence, nous avons constitué une base de données trimestrielle couvrant la période allant de T1 2006 à T4 2021, ce qui nous a donné 64 observations. (Annexe1)

- La variable à expliquer :

La variable que nous utilisons pour mesurer le risque de crédit est le ratio des prêts non performants. Cette variable est couramment utilisée dans la littérature comme un indicateur de mesure du risque de crédit. (Annexe2)

Figure 2 : L'évolution des prêts non performants



Source : élaborer par l'auteur à l'aide de Excel

D'après le graphique ci-dessus, nous constatons une tendance à la hausse des NPL depuis la création de la banque jusqu'à aujourd'hui. Le niveau des prêts non performants de la BFPME a atteint un niveau élevé de 83,52 % en 2021 en raison de la nature de son activité et de la faiblesse de son modèle économique en tant que banque d'investissement.

- **Les variables explicatives :**

Pour identifier les variables explicatives du risque de crédit, nous nous sommes inspirés des recherches précédentes menées par (Dimitrios, Angelos, & Vouldis, 2012), (Alexandri & Santoso, 2015), ainsi que (Messai & Jouini, 2013). Le tableau ci-dessous présente les variables explicatives que nous avons incluses dans notre modèle.

Tableau 3 : Les variables micros et macros économiques

	Variables	Mesure	Description
Variables Spécifique	ROA	Rentabilité des actifs $\frac{\text{résultat net}}{\text{total actifs}}$	Les banques non rentables sont davantage incitées à sélectionner soigneusement leurs clients afin d'améliorer la qualité de leur portefeuille.
	PCC	Provisions sur créances classés	Les banques ont tendance à constituer des provisions lorsqu'elles anticipent des niveaux élevés de pertes.
Variables Macroéconomique	IPC	Indice des Prix à la Consommation	Permet de mesurer l'évolution du niveau moyen des prix des biens et services consommés par les ménages et permet d'analyser l'impact inflationniste.
	IPI	Indice de Production Industrielle	C'est un instrument statistique qui mesure les variations des quantités produites dans l'industrie.
	TMM	Taux de Marché Monétaire	C'est le taux d'intérêt sur le marché monétaire qui présente un instrument d'indexation pour les banques, en termes de crédit, de dépôt à terme et d'épargne.
	USD	Taux de Change USD/TND	La dépréciation de la monnaie locale entraîne une détérioration du portefeuille de clients libellé en devise étrangère.

Source : préparer par l'auteur

2. Estimation des modèles

Pour étudier l'impact des variables spécifiques à la banque et des variables macroéconomiques sur le risque de crédit au sein de la BFPME, nous avons d'abord effectué plusieurs tests à l'aide du logiciel R-CRAN avant de procéder à l'estimation des modèles.

2.1. Application du modèle VECM

2.1.1. Les tests des pré-estimations

- Test de la racine unitaire :

Dans ce test, nous nous intéressons à l'analyse du niveau d'intégration des variables. Pour ce faire, nous utilisons les tests (Dickey & Fuller, 1981) et (Kwiatkowski, Phillips, Schmidt, & Shin, 1992) de la racine unitaire sur chaque variable, en utilisant les commandes (adf.test, kpss.test) fournies par le package « tseries » du logiciel R.

Tableau 4 : Test de la racine unitaire

Variable	Test de la racine unitaire			
	ADF	P-value	KPSS	P-value
NPL(0)	-1.248	0.879	1.660	0.01
ROA(0)	-1.327	0.847	0.524	0.036
PCC(0)	-1.341	0.842	1.458	0.01
IPC(0)	-3.041	0.153	1.677	0.01
IPI(0)	-3.283	0.082	1.678	0.01
TMM(0)	-2.782	0.258	0.771	0.01
USD(0)	-2.167	0.507	1.580	0.01
NPL(1)	-2.251	0.01	0.346	0.1
ROA(1)	-3.815	0.023	0.235	0.1
PCC(1)	-4.198	0.01	1.006	0.1
IPC(1)	-4.880	0.01	0.063	0.1
IPI(1)	-4.398	0.01	0.174	0.1
TMM(1)	-3.004	0.01	0.106	0.1
USD(1)	-4.105	0.011	0.237	0.1

Source : préparer par l'auteur à l'aide de logiciel R CRAN

Pour le test ADF l'hypothèse nulle est celle de non stationnarité, tandis que pour le test KPSS l'hypothèse nulle est la stationnarité. D'après les résultats illustrés dans le tableau ci-dessus, nous remarquons que toutes les variables du modèle sont non stationnaires en niveau, et stationnaires en différence. Par conséquent, les variables du modèle sont toutes intégrées d'ordre 1. (Annexe3)

- Détermination de l'ordre du retard :

Pour la détermination du nombre de retard du modèle VAR correspondant, nous avons utilisé la commande « VARselect » du package « vars », qui offre 4 critères de sélection du nombre de retard, à savoir : le critère (Akaike, 1974), le critère de (Hannan & Quinn, 1979), le critère de (Schwarz, 1978) et le critère d'erreur de prévision (FEP). Les résultats sont présentés dans le tableau ci-dessous :

Tableau 5 : Détermination du nombre des retards

Lag.max	AIC(n)	HQ(n)	SC(n)	FPE(n)
1	-	-	-	-
2	2	1	1	2
3	2	1	1	2
4	2	1	1	2
5	2	2	2	2

Source : préparer par l'auteur à l'aide de logiciel R CRAN

Selon les résultats obtenus, nous constatons que le nombre de retard optimal choisi est de 2 selon les suggestions des critères. Par conséquent nous affirmons que nous sommes en présence d'un modèle $VAR(p = 2)$. (Annexe4)

- **Test de cointégration :**

L'économétrie des séries non stationnaires a connu un développement à travers la théorie de la cointégration, qui a été développée par (Engle & Granger, 1987) (Johansen, 1988) et (Johansen, 1991). Ces auteurs ont présenté une solution plausible, dans le cas de non stationnarité avec des variables dites intégrées d'ordre 1. Cette approche consiste à dégager des relations d'équilibre de long terme entre les différentes variables du modèle, appelé des relations de cointégration.

Tableau 6 : Les résultats du Test de cointégration

H0	Valeurs du test	Valeurs Critiques		
	Lag = 2	90%	95%	99%
$r = 0$	48.69	42.06	44.91	51.30
$r \leq 1$	33.93	36.25	39.43	44.59
$r \leq 2$	25.07	30.84	33.32	38.78
$r \leq 3$	15.36	24.78	27.14	32.14
$r \leq 4$	12.62	18.90	21.07	24.75
$r \leq 5$	9.92	12.91	14.90	19.19
$r \leq 6$	0.09	6.50	8.18	11.65

Source : préparer par l'auteur à l'aide de logiciel R CRAN

D'après ces résultats, nous concluons que notre modèle $VAR(2)$ présente une seule équation de cointégration, car l'hypothèse $H_0: r \leq 1$ est acceptée tandis que $r = 0$ est rejeté. En d'autres termes, nos variables intégrées d'ordre 1 sont liées entre elles en niveau par une équation d'équilibre de long terme. (Annexe5)

2.1.2. Estimation du modèle VECM

En effet, l'estimation du modèle VECM permet de déterminer le vecteur de la cointégration β . Pour ce faire, nous nous appuyons sur les procédures d'estimation fournies par le package «vars» du logiciel R. Ainsi, l'équation de cointégration nous offre une forme d'équilibre de long terme, laquelle est obtenue à partir de l'équation de cointégration suivante (Annexe6) :

$$\varepsilon_{t-1} = NPL_{t-1} + 2.41ROA_{t-1} - 7.42PCC_{t-1} + 160.74IPC_{t-1} - 368.55IPI_{t-1} - 5.33TMM_{t-1} - 88.61USD_{t-1}$$

En se basant sur ces résultats d'estimation, nous pouvons dériver l'équation du modèle VECM comme suit :

$$\begin{aligned} NPL_t = & -17.838 + 0.665 NPL_{t-1} + 0.059 ROA_{t-1} + 0.443 PCC_{t-1} - 3.509 IPC_{t-1} - 5.066 IPI_{t-1} \\ & + 0.406 TMM_{t-1} - 2.239 USD_{t-1} + 0.071 NPL_{t-2} - 0.230ROA_{t-2} + 0.363 PCC_{t-2} \\ & - 4.832 IPC_{t-2} - 2.758 IPI_{t-2} + 0.165 TMM_{t-2} - 1.974 USD_{t-2} + \varepsilon_t \end{aligned}$$

Les résultats de validation du modèle VECM montrent, selon l'annexe 7, que les résidus sont stationnaires, non corrélés et suivent la loi normale d'après les tests ADF, Breusch-Godfrey et Jarque Bera respectivement. Enfin, les résultats du test d'hétéroscédasticité montrent que la probabilité associée est supérieure à 5%, ce qui signifie l'existence d'Homoscédasticité des résidus. (Annexe7)

2.2. Application de l'approche BSVAR


Dans le cadre de notre objectif d'étude, nous introduirons, dans cette partie, l'approche de la statistique structurelle et bayésienne en utilisant les mêmes variables que celles employées dans le modèle VECM.

Dans la méthode scientifique, il existe deux types de probabilités différents, ce qui peut créer de la confusion parmi les chercheurs. Ce sont fondamentalement deux façons de penser distinctes, qui visent à élaborer des opinions sur le fonctionnement de la nature et la composition de la réalité.

La principale différence entre les deux approches réside dans le fait que l'approche fréquentiste raisonne en termes de vraisemblance, tandis que l'approche bayésienne raisonne en termes de plausibilité (ou crédibilité) des hypothèses. La raison qui explique ce choix par les fréquentistes est qu'ils estiment que l'approche bayésienne comporte deux critiques majeures :

- **Trop complexe :** Ce n'est pas le cas lorsque des logiciels et des algorithmes sophistiqués tels que le logiciel R-CRAN sont disponibles. Pour remédier à ce problème, les fréquentistes raisonnent en termes de vraisemblance à travers la statistique de Fisher, qui se base sur des intervalles de confiance fixés par les chercheurs, pouvant aller jusqu'à 10 % pour accepter une hypothèse. Cela pose un problème majeur, en particulier dans les cas de crises et de stress. En revanche, l'approche bayésienne fonctionne par inférence, ce qui signifie qu'il n'y a pas de rejet des hypothèses, mais au fil de nombreuses itérations, on s'approche de la réalité, avec la possibilité de prendre en compte toutes les hypothèses existantes et/ou d'intégrer de nouvelles hypothèses.
- **Trop subjectif :** Cette objection ne tient pas non plus, car la statistique fréquentiste utilise également une forme de subjectivité, en particulier à travers le principe de parcimonie, souvent appelé « le Rasoir d'Ockham ».

Figure 3 : Différences entre les approches fréquentiste et bayésienne



Source : Livre formule du savoir Lê Nguyễn 2018

D'après (Nguyễn, 2018), la statistique bayésienne est une méthode globale qui a une grande portée philosophique et qui contribue significativement à une réflexion approfondie. Elle répond de manière adaptée au contexte des tests de stress en évaluant la plausibilité des hypothèses et en intégrant une dimension critique pour les décideurs.

Cependant, avant de pouvoir procéder à ce traitement, il est nécessaire de spécifier des contraintes d'identification. Dans notre cas, avec un modèle à sept variables, nous sommes amenés à introduire 21 contraintes d'identification, conformément à la règle $(k(k - 1)/2)$.

Par conséquent, en s'inspirant, principalement, des travaux de (Sims & Zha, 1998) et de (Waggoner & Zha, 2003), on définira le cadre de notre modèle BSVAR, surtout concernant la nature et les spécificités de la distribution à priori.

2.2.1. Spécification des contraintes d'identification

La modélisation SVAR est une extension de la modélisation VAR, qui est établie comme une démarche a-théorique, se limitant à l'étude de la dynamique des variables sans aucune identification économique. Pour remédier à cette limitation, nous mettons en avant l'émergence des modèles SVAR. En effet, une étape essentielle de la modélisation SVAR consiste à incorporer des relations instantanées qui influencent les liens entre les différentes variables. Cette incorporation permet de passer des chocs issus d'un modèle VAR purement subjectif à des chocs pouvant être interprétés économiquement, comme décrit dans les travaux de (Hamilton, 1994) et (Lütkepohl, 2005).

Dans un premier temps, pour établir nos contraintes d'identification, nous avons examiné de nombreux articles et travaux sur les stress tests dans différents pays. À la suite de cette revue de littérature, nous avons constaté qu'à chaque étude, il y avait une spécificité dans l'introduction des contraintes, qui dépendait parfois du pays, de la banque, ou de la période de l'étude. Face à ces variations dans les choix effectués par les auteurs, nous avons cherché à utiliser une méthode plus fiable, de manière à obtenir un modèle qui se rapproche davantage de la réalité, en fonction des données dont nous disposons.

Dans notre cas, nous utiliserons le test de Granger sur le logiciel R, afin de spécifier toutes les relations de causalité entre les variables du modèle. Ainsi, l'absence de la causalité sera considérée comme une contrainte d'identification. (Annexe8)

Tableau 7 : Les résultats du Test de Causalité de Granger

H0	Fischer	P-value	Hypothèse retenue
ROA ne cause pas NPL	2.4833	0.0241**	Présence de causalité
PCC ne cause pas NPL	1.9822	0.0683*	Présence de causalité
IPC ne cause pas NPL	2.8398	0.0116**	Présence de causalité
IPI ne cause pas NPL	1.6057	0.1484	Absence de causalité
TMM ne cause pas NPL	3.8432	0.0271**	Présence de causalité
USD ne cause pas NPL	2.8862	0.0105**	Présence de causalité

NPL ne cause pas ROA	7.3922	0.0621*	Présence de causalité
PCC ne cause pas ROA	17.872	0.0179**	Présence de causalité
IPC ne cause pas ROA	7.2888	0.0633*	Présence de causalité
IPI ne cause pas ROA	2.0403	0.0605*	Présence de causalité
TMM ne cause pas ROA	1.1727	0.5185	Absence de causalité
USD ne cause pas ROA	2.2921	0.0358**	Présence de causalité
NPL ne cause pas PCC	1.1063	0.3864	Absence de causalité
ROA ne cause pas PCC	0.1105	0.9996	Absence de causalité
IPC ne cause pas PCC	2.3877	0.0294**	Présence de causalité
IPI ne cause pas PCC	2.1047	0.0529*	Présence de causalité
TMM ne cause pas PCC	0.7339	0.6877	Absence de causalité
USD ne cause pas PCC	2.5389	0.0878*	Présence de causalité
NPL ne cause pas IPC	1.0793	0.4051	Absence de causalité
ROA ne cause pas IPC	0.4268	0.9230	Absence de causalité
PCC ne cause pas IPC	0.1878	0.8293	Absence de causalité
IPI ne cause pas IPC	1.154	0.3550	Absence de causalité
TMM ne cause pas IPC	1.8866	0.0833*	Présence de causalité
USD ne cause pas IPC	4.1253	0.0212**	Présence de causalité
NPL ne cause pas IPI	1.1165	0.3795	Absence de causalité
ROA ne cause pas IPI	0.5768	0.8208	Absence de causalité
PCC ne cause pas IPI	1.5184	0.1768	Absence de causalité
IPC ne cause pas IPI	2.1539	0.0533*	Présence de causalité
TMM ne cause pas IPI	2.3861	0.0295**	Présence de causalité
USD ne cause pas IPI	0.7471	0.6761	Absence de causalité
NPL ne cause pas TMM	1.2731	0.2850	Absence de causalité
ROA ne cause pas TMM	0.022	0.9782	Absence de causalité
PCC ne cause pas TMM	1.0099	0.4559	Absence de causalité
IPC ne cause pas TMM	52.123	0.0037***	Présence de causalité
IPI ne cause pas TMM	4.2481	0.0190**	Présence de causalité
USD ne cause pas TMM	0.6448	0.7650	Absence de causalité
NPL ne cause pas USD	0.4278	0.9224	Absence de causalité
ROA ne cause pas USD	0.587	0.8127	Absence de causalité
PCC ne cause pas USD	1.402	0.2225	Absence de causalité
IPC ne cause pas USD	0.7544	0.6697	Absence de causalité
IPI ne cause pas USD	2.4226	0.0977*	Présence de causalité
TMM ne cause pas USD	2.6292	0.0808*	Présence de causalité

Source : préparé par l'auteur à l'aide de logiciel R CRAN

Par conséquent, d'après les tests effectués, nous retenons 21 contraintes d'identification de court terme. La matrice des effets instantanés aura donc la forme suivante :

$$A_0 = \begin{pmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 & 1 & 1 & 1 \\ 1 & 0 & 0 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 & 0 & 1 \end{pmatrix}$$

2.2.2. Détermination de la distribution à priori

Le théorème de Bayes, introduit par Thomas Bayes et généralisé par Simon Laplace, est largement utilisé dans de nombreuses applications en tant qu'outil puissant pour l'inférence statistique. Conformément à la loi de Bayes, nous avons l'équation suivante :

$$p(\theta|y) = \frac{p(y|\theta) p(\theta)}{p(y)}$$

Distribution à priori θ \times fonction de vraisemblance y = Distribution à posteriori θ ;

Croyance a priori \times fonction de vraisemblance = Croyance a posteriori

Toutefois, la distribution à priori suppose une loi définie par le modélisateur pour déterminer la distribution à posteriori après combinaison avec l'information disponible. L'étape la plus délicate de l'approche bayésienne réside dans la détermination de la distribution à priori, qui reflète l'état d'esprit des décideurs. En effet, un mauvais choix de celle-ci peut nuire à l'ensemble des résultats du modèle, ce qui peut ensuite influencer les chocs du stress test. Pour cette raison, de nombreux auteurs accordent une grande importance au choix des meilleures distributions à priori pour obtenir de bons résultats.

Plusieurs articles de recherche ont abordé la question des distributions à priori, ainsi que de nombreux travaux récents sur le sujet. Parmi ces travaux, citons celui de (Sims & Zha, 1998), qui suppose que la meilleure distribution à priori pour un modèle *SVAR*(6) avec des données trimestrielles est la suivante :

$$\lambda_0 = 1, \lambda_1 = 0.2, \lambda_3 = 1, \lambda_4 = 1, \mu_5 = 1 \text{ et } \mu_6 = 1$$

λ_0 : Contrôle le degré de confiance dans les coefficients de la matrice des effets instantanés A_0 et il s'agit d'un réel appartenant à l'intervalle $[0,1]$.

λ_1 : Indique le niveau de confiance par rapport à l'hypothèse proposée par Litterman, qui suppose que chaque variable suit une marche aléatoire, c'est un réel appartenant à $[0,1]$.

λ_3 : Contrôle le taux de décroissance de la variance des données compte tenu de l'augmentation du retard avec $\lambda_3 \geq 0$.

λ_4 : L'écart type autour de la tendance déterministe avec $\lambda_4 \geq 0$. Ce paramètre représente la variabilité résiduelle des données après avoir soustrait la tendance.

λ_5 : L'écart type autour des coefficients des variables exogènes. Si $\lambda_5 = 0$, cela signifie que notre modèle ne contient pas de variable exogène.

$\mu_5 = 1$: il s'agit des observations Dummy pour améliorer les performances des prévisions.

$\mu_6 = 1$: il s'agit de l'à priori de la racine unitaire, ce qui permet de remettre en cause les problèmes de la stationnarité des séries.

Ainsi, pour aboutir à la meilleure distribution à priori, on simulera plusieurs cas des figures, selon la variation des différents hyperparamètres, et nous choisirons l'ensemble de ces derniers qui nous offriront la meilleure estimation, la meilleure prévision et la meilleure information représentative du modèle. Pour ce faire, notre choix se basera sur les trois indicateurs statistiques suivants :

- RMSE : la racine carrée de l'erreur quadratique moyenne ;
- MAE : l'erreur absolue moyenne ;
- LogMDD : le logarithme de la densité marginale.

Par conséquent, notre procédure de choix se déroulera comme suit :

- Nous sélectionnons la distribution qui fournit la plus faible RMSE.
- Nous sélectionnons la distribution qui fournit la plus faible MAE.
- Si nous obtenons la même distribution, alors nous nous arrêtons.
- Si non ; nous choisirons la distribution qui a la plus grande densité marginale.

En utilisant la commande «SZ.prior.evaluation» de package « MSBVAR » du logiciel R, qui donne pour chaque combinaison des hyperparamètres, les indicateurs statistiques (RMSE, MAE et LogMDD).

En tenant compte du domaine de définition de chaque hyperparamètre, nous ferons varier les valeurs de ces derniers, jusqu'à l'obtention de la meilleure combinaison.

- **Première simulation :**

$$\lambda_0 = \lambda_1 = (0.1, 0.2, 0.3) ; \lambda_3 = \lambda_4 = (1, 2, 3) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,3	0,3	1	3	0	1	1	2.362193	_	639.0717
MAE	0,3	0,3	1	3	0	1	1	_	1.265337	639.0717

Toutefois, nous remarquons que les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 prennent leurs valeurs possibles maximales. En d'autres termes, pour l'hyperparamètre λ_0 une valeur supérieure à 0.3 pourrait nous fournir une meilleure densité à priori. Par conséquent, nous recourons à une deuxième simulation.

- **Deuxième simulation :**

$$\lambda_0 = \lambda_1 = (0.3, 0.4, 0.5) ; \lambda_3 = (0, 0.5, 1) ; \lambda_4 = (10, 20, 30) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,5	0,5	0	30	0	1	1	2.146183	_	559.7508
MAE	0,5	0,5	0	30	0	1	1	_	1.115123	559.7508

Néanmoins, la constatation que les hyperparamètres λ_0 , λ_1 et λ_4 atteignent leur valeur maximale possible nous a poussés à effectuer une troisième simulation.

- **Troisième simulation :**

$$\lambda_0 = \lambda_1 = (0.5, 0.6, 0.7) ; \lambda_3 = 0 ; \lambda_4 = (30, 60, 100) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,7	0,7	0	100	0	1	1	2.098788	_	501.2995
MAE	0,7	0,7	0	100	0	1	1	_	1.079721	501.2995

Cependant, il est important de noter que les hyperparamètres λ_0 , λ_1 et λ_4 atteignent leur valeur maximale possible, ce qui nous a incités à procéder à une quatrième simulation.

- **Quatrième simulation :**

$$\lambda_0 = \lambda_1 = (0.7, 0.8, 0.9) ; \lambda_3 = 0 ; \lambda_4 = (100, 200, 300) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,9	0,9	0	300	0	1	1	2.073019	_	463.8065
MAE	0,9	0,9	0	300	0	1	1	_	1.070217	463.8065

Cependant, nous avons observé que les hyperparamètres λ_0 , λ_1 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous avons décidé d'effectuer une cinquième simulation.

Cinquième simulation :

$$\lambda_0 = \lambda_1 = (0.9, 1) ; \lambda_3 = 0 ; \lambda_4 = (300, 400, 500, 600, 700, 800, 900) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	1	1	0	600	0	1	1	2.065220	_	449.6753
MAE	1	1	0	600	0	1	1	_	1.068554	449.6753

Cette fois, les hyperparamètres λ_0 , λ_1 et λ_4 ont abouti à des valeurs intermédiaires ou maximales. Par conséquent, nous arrêtons le processus de simulation des distributions à priori. Certes, nous avons multiplié les simulations afin de tomber sur une meilleure distribution à priori. Mais, afin d'affirmer sur la meilleure qualité de la distribution à priori retenue suite à la cinquième simulation, nous comparerons tous les résultats retenus précédemment. Nous considérerons aussi, les hyperparamètres de référence de l'article de Sims et Zha. (Annexe9)

Tableau 8 : Les résultats des simulations pour le choix de la distribution à priori

Simulation	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
Priori 1	0.3	0.3	1	3	0	1	1	2.362193	1.265337	639.0717
Priori 2	0.5	0.5	0	30	0	1	1	2.146183	1.115123	559.7508
Priori 3	0.7	0.7	0	100	0	1	1	2.098788	1.079721	501.2995
Priori 4	0.9	0.9	0	300	0	1	1	2.073019	1.070217	463.8065
Priori 5	1	1	0	600	0	1	1	2.065220	1.068554	449.6753
Priori SZ	1	0,2	1	1	0	1	1	2.110103	1.156807	256.6349

Source : préparé par l'auteur à l'aide de logiciel R-CRAN

D'après le tableau ci-dessus, nous remarquons que la combinaison qui nous offre le couple (RMSE, MAE) le plus faible est celle de la cinquième simulation. Par conséquent nous retenons une distribution à priori avec les hyperparamètres suivants :

$$\lambda_0 = 1, \lambda_1 = 1, \lambda_3 = 0, \lambda_4 = 600, \mu_5 = 1 \text{ et } \mu_6 = 1$$

2.2.3. Estimation du modèle BSVAR

En considérant le même modèle VECM étudié et en introduisant la matrice des restrictions ainsi que la distribution à priori choisie sur les paramètres, nous allons déterminer les distributions à posteriori de chaque paramètre du modèle SVAR. L'approche de Sims et Zha est implémentée au niveau de la commande « szbsvar » du package « MSBVAR » du logiciel R. Une fois que les distributions à posteriori sont déterminées via cette procédure, nous utilisons les procédures « gibbs.A0 » et « A02mcmc » afin de déterminer la distribution à posteriori complète de la matrice. (Annexe10)

Nous commençons par la présentation du résultat graphique, qui contient les courbes des distributions à posteriori des coefficients de la matrice, en raison de l'introduction des contraintes de court terme. Le graphique présenté dans l'annexe 11 représente la distribution à posteriori selon l'approche de Gibbs. Afin de mieux expliquer la signification de cette matrice, nous avons extrait les résultats des simulations dans un fichier plat (.csv), que nous avons ensuite converti en fichier Excel. Ensuite, nous avons procédé à une analyse descriptive pour déterminer la moyenne empirique ainsi que l'écart type de chaque coefficient de la matrice des effets instantanés. Ci-dessous, nous présentons la matrice récapitulative des informations descriptives sur la distribution à posteriori.

Tableau 9 : Les moyennes et les écarts-type des distributions à posteriori

	NPL	ROA	PCC	IPC	IPI	TMM	USD
NPL	-0,65852 (1,52892)	1,14834 (1,66074)	–	–	–	–	–
ROA	1,08552 (1,14605)	1,11938 (1,61311)	–	–	–	–	–
PCC	-1,37304 (0,29447)	0,14720 (0,33659)	6,29594 (0,5312)	–	–	–	–
IPC	-0,53936 (0,38697)	-0,11303 (0,3411)	0,79840 (0,87597)	5,78654 (14,7802)	4,42422 (15,3623)	3,06309 (1,57875)	–
IPI	–	0,44071 (0,36207)	-0,56155 (0,68539)	–	0,06473 (11,9995)	0,14051 (1,58542)	-14,521 (4,2782)
TMM	0,04196 (0,41042)	–	–	2,10889 (20,418)	15,84750 (8,15899)	-1,41806 (2,21264)	-0,3852 (9,2289)
USD	-0,62389 (0,32689)	-0,29551 (0,35802)	-2,36066 (0,77881)	117,8862 (10,3075)	–	–	-3,34514 (2,9545)

Source : préparé par l'auteur à l'aide de logiciel R-CRAN

Les résultats empiriques présentés dans le tableau précédent nous fournissent une idée de la nature des distributions à posteriori calculées pour chaque coefficient de la matrice des effets instantanés. Les résultats des distributions à posteriori des paramètres structurels seront exposés dans l'annexe. (Annexe11)

2.3.Comparaison des performances entre les modèles VECM et BSVAR

Dans ce cadre, pour procéder à une comparaison des performances entre le modèle VECM et le modèle BSVAR, nous comparons les deux modèles en s'appuyant sur le critère de l'erreur quadratique moyenne de prévision. Ensuite, nous utiliserons le test de Diebold- Mariano pour analyser la significativité de différence des deux modèles en termes d'erreur de prévision. Enfin, nous terminerons notre travail de comparaison par le test de Harvey, Leybourne et Newbold pour voir s'il y a un modèle qui pourrait expliquer la prévision combinée.

2.3.1. Critère de l'Erreur Quadratique Moyenne de Prévision

Considérons deux modèles économétriques $M1$ et $M2$ qui expliquent les variables y_t pour $t \in (1, T)$. Découpons l'intervalle en deux tel que : $(1, T) = (1, T_0) \cup (T_0, T)$, nous estimons les deux modèles considérés sur la période $(1, T_0)$, et sur la base des résultats, nous formons deux séries de prévisions, $y_t^{p,1}$ et $y_t^{p,2}$ sur l'intervalle (T_0, T) . L'EQMP est calculée en se basant sur les observations réelles sur l'intervalle (T_0, T) . Par conséquent, nous obtiendrons :

$$EQMP_i = \sqrt{E \left((y_*^{p,i} - y_*)^2 \right)} \quad \text{avec } y_* = (y_{T_0}, \dots, y_T) \text{ et } y_*^{p,i} = (y_{T_0}^{p,i}, y_T^{p,i}).$$

Nous rappelons que notre base de données contient 64 observations, s'étalant du T1 2006 jusqu'au T4 2021. Ainsi, pour effectuer notre démarche de comparaison, nous passons principalement par les étapes suivantes :

- Nous estimons les deux modèles pour une série d'observations allant du T1 2006 au T2 2019, et nous simulerons les prévisions sur les 10 périodes restantes.
- Ensuite, pour la deuxième étape, nous considérons pour les estimations la période du T1 2006 au T1 2018, et nous simulerons les prévisions pour les 15 périodes restantes.
- Enfin, les prévisions simulées s'étaleront sur 20 périodes entre T1 2017 et le T4 2021.

Sur la base des différentes prévisions simulées, nous calculerons l'EQMP variable par variable et du modèle, une valeur plus petite indique une meilleure performance du modèle.

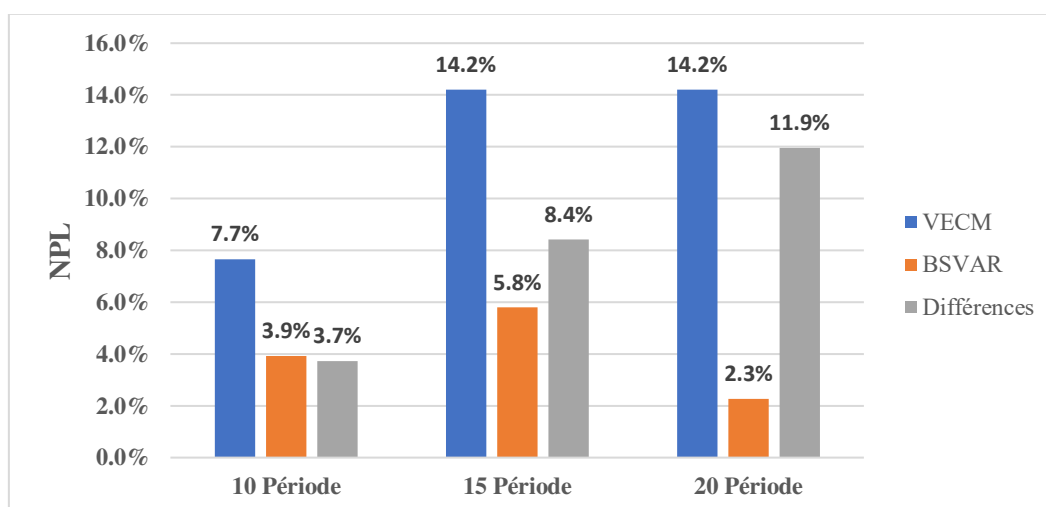
Tableau 10 : Les résultats de l'indice EQMP

		EQMP		Différence VECM BSVAR
		VECM	B-SVAR	
10 périodes	NPL	7.665	3.932	3.733
	ROA	0.940	0.814	0.126
	PCC	1.416	0.284	1.132
	IPC	0.008	0.025	-0.017
	IPI	0.070	0.129	-0.060
	TMM	1.399	1.702	-0.303
	USD	0.313	0.450	-0.137
	TOTAL	11.810	7.336	7.475
15 périodes	NPL	14.218	5.798	8.419
	ROA	0.761	1.600	-0.839
	PCC	2.466	0.264	2.202
	IPC	0.013	0.094	-0.081
	IPI	0.063	0.127	-0.064
	TMM	0.875	1.146	-0.271
	USD	0.252	0.247	0.005
	TOTAL	18.648	9.278	9.370
20 périodes	NPL	14.210	2.265	11.945
	ROA	6.124	5.470	0.654
	PCC	2.418	0.971	1.447
	IPC	0.062	0.097	-0.035
	IPI	0.057	0.122	-0.065
	TMM	2.435	2.392	0.043
	USD	0.259	0.492	-0.233
	TOTAL	25.566	11.811	13.755

Source : préparé par l'auteur à l'aide de logiciel R CRAN

D'après le tableau ci-dessus, nous remarquons que d'un point de vue global, le modèle BSVAR offre dans tous les cas des meilleures prévisions que celles produites par le modèle VECM, vu que l'indice de l'EQMP du modèle BSVAR est plus faible que celui du modèle VECM. Par conséquent, l'intégration de l'approche bayésienne a amélioré la précision du modèle.

Figure 4 : EQMP des NPL



Source : préparé par l'auteur à l'aide de logiciel R CRAN

Ainsi, le graphique ci-dessus nous montre la différence entre les erreurs de prévision des NPL des deux modèles. Nous observons une différence croissante entre les erreurs des deux modèles, passant de 3,7% sur 10 périodes à 11,9% sur 20 périodes. Cela prouve clairement que le modèle BSVAR possède une meilleure robustesse et stabilité au fil du temps. (Annexe12)

Nous pouvons conclure que l'introduction de l'identification structurel et l'information a priori ont amélioré le potentiel de précision de la modélisation. En effet, la considération d'une information supplémentaire a un effet positif sur les prévisions des NPL. Cependant, il faut vérifier que cette différence est significative statistiquement. Pour résoudre ce problème, nous recourons au test de Diebold-Mariano.

2.3.2. Test de Diebold-Mariano

Le test de (Diebold & Mariano, 1995) compare la précision de prévision de deux méthodes de prévision. L'hypothèse nulle est, qu'ils ont la même précision de prévision. Cette hypothèse montre que même s'il y a une différence entre les fonctions de perte des deux modèles, cette dernière n'est pas significative. La statistique du test est définie par :

$$DM = \frac{\bar{d}\sqrt{T}}{\sqrt{\hat{\sigma}_{DW}}}$$

Avant de procéder au test, nous passons par un travail préliminaire comme suit :

- Nous gardons les séries des prévisions utilisées pour le calcul de l'EQMP (10 périodes, 15 périodes et 20 périodes).
- Nous déterminons par la suite les fonctions de perte $L(\varepsilon_t^i)$.
- Nous calculons la série d_t de la différence entre les deux fonctions de perte. Ainsi, nous pouvons former une matrice de différence des fonctions de perte notée D.
- Nous déterminons la quantité \bar{d} pour chaque variable, ainsi que l'estimation de la variance de long terme de chaque vecteur de la matrice D. A l'aide du package «sandwich» du logiciel R, on trouve la commande «lrvar» qui nous déterminera l'estimation de la variance de long terme de chaque vecteur d_t .
- Nous déterminons la valeur de la statistique DM et nous la comparons par rapport à la distribution normale centrée réduite à un niveau de confiance de 95%. Par conséquent, si $|DM| > 1.96$, alors l'hypothèse de l'égalité entre les fonctions de perte est rejetée avec un risque d'erreur de 5%.

Les résultats empiriques sont exposés au niveau du tableau suivant. Si la différence entre les fonctions de perte des deux modèles est significative, la statistique DM calculée sera noté «*».

Tableau 11 : Les résultats du test de Diebold-Mariano

	NPL	ROA	PCC	IPC	IPI	TMM	USD
10 périodes	-10.307*	-1.337	-13.183*	11.420*	8.466*	10.575*	14.098*
15 périodes	-16.251*	13.393*	-21.978*	16.590*	10.947*	6.317*	-0.446
20 périodes	-16.835*	-11.350*	-18.349*	15.970*	10.842*	-6.398*	8.638*

Source : préparé par l'auteur à l'aide de logiciel R CRAN

D'après le tableau Ci-dessus, nous remarquons qu'il y a une différence significative entre les fonctions de perte fournies par les deux modèles dans tous les cas des figures sauf les variables ROA sur 10 périodes et USD sur 15 périodes. Donc nous pouvons conclure que l'approche bayésienne a amélioré le pouvoir prédictif de la modélisation en introduisant la distribution à priori. (Annexe12)

Certes, dans la plupart des cas, la prévision fournie par l'approche bayésienne est la meilleure, vu qu'elle améliore la précision. Mais, nous pouvons tomber sur une prévision combinée qui améliore même les prévisions de l'approche bayésienne. Pour répondre à cette problématique, nous recourons au test de dominance proposé (Harvey, Leybourne, & Newbold, 1998), pour voir si nous pouvons trouver une meilleure prévision à partir des deux modèles, ou si un des modèles domine l'autre et par conséquent il formera seul la meilleure prévision.

2.3.3. Test de la dominance de prévision

Plusieurs auteurs tels que (Granger & Newbold, 1986), nous ont fait remarquer qu'il était possible d'améliorer les prévisions des deux modèles retenus en partant du principe de la prévision combinée. En effet, ils ont montré l'existence d'un réel $\lambda \in [0,1]$, tel que la nouvelle projection $y_t^{p,c} = (1 - \lambda)y_t^{p,1} + \lambda y_t^{p,2}$.

Toutefois, si par exemple le modèle M1 est riche en information et donne déjà la meilleure prévision, alors nous tomberons sur un paramètre $\lambda = 0$, et dans ce cas nous dirons que le modèle M1 domine le modèle M2.

- Nous gardons les séries des prévisions utilisées pour le calcul de l'EQMP (10 périodes, 15 périodes et 20 périodes).
- Nous calculons les écarts par rapport aux observations réalisées ($e_{BSVAR,t}$ et $e_{VECM,t}$) pour déterminer finalement la fonction du test $f_t = e_{VECM,t}(e_{VECM,t} - e_{BSVAR,t})$
- Nous déterminons la quantité \bar{f} pour chaque variable, ainsi que l'estimation de la variance de long terme $\hat{\sigma}_{HLN}$ de chaque vecteur de la matrice.

- Enfin, nous déterminons la valeur de la statistique $HLN = \frac{\sqrt{T-T_0}\bar{f}}{\hat{\sigma}_{HLN}}$ avec l'hypothèse nulle du test est $H_0: E(f_t) = 0$.

Si l'hypothèse de la domination des prévisions fournies par l'approche VECM est valide, nous noterons la statistique HLN calculée par «*» :

Tableau 12 : Les résultats du test de la dominance des prévisions

	NPL	ROA	PCC	IPC	IPI	TMM	USD
10 périodes	9.749	7.465	12.021	4.554	-6.534	-9.862	-12.943
15 périodes	14.384	-8.015	19.498	9.487	-7.741	5.808	14.688
20 périodes	15.707	5.060	12.617	-19515	-7512.8	-144.19	-427.07

Source : préparer par l'auteur à l'aide de logiciel R CRAN


D'après ce tableau, nous constatons que l'hypothèse nulle (les prévisions du modèle VECM dominant celles du modèle BSVAR) est rejetée dans tous les cas. Par conséquent, nous pouvons dire que les prévisions fournies par le modèle BSVAR sont, certes, meilleures que celles fournies par le modèle VECM, d'après les tests précédents. Cependant, ces dernières peuvent être améliorées en jouant sur la notion de la combinaison des prévisions. (Annexe12)

2.4. Analyse des chocs structurels et décomposition de la variance

La logique de l'estimation par l'approche bayésienne permet d'imposer l'aspect dynamique entre les variables qui dépend de la distribution à postérieur de chaque paramètre de l'estimation. A l'aide de la fonction d'impulsion, nous pouvons déduire l'impact d'un choc des variables ROA, PCC, IPC, IPI, TMM et USD sur la variable NPL.

D'après les graphes ci-dessous nous constatons que le choc des variables NPL, PCC, IPC, IPI et TMM ont un effet positif sur la variable NPL. Tandis que les variables ROA et USD ont un impact négatif sur la variable NPL à court terme et long terme. (Annexe13)

Figure 5 : Les fonctions d'impulsion



Source : préparer par l'auteur à l'aide de logiciel R CRAN

Le modèle BSVAR estimé va nous permettre de faire une décomposition de la variance, l'objectif de cette décomposition est de calculer la contribution de chacune des innovations à la variance de l'erreur. Le tableau suivant présente les résultats à l'étude de la décomposition de la variance pour la série NPL :

Tableau 13 : Décomposition de la variance pour les NPL

Période	NPL	ROA	PCC	IPC	IPI	TMM	USD
1	91.5026%	2.9532%	4.5647%	0.0073%	0.0019%	0.9649%	0.0051%
2	92.6854%	4.4885%	2.5300%	0.0036%	0.0004%	0.2905%	0.0012%
3	92.2199%	5.9327%	1.7150%	0.0022%	0.0003%	0.1290%	0.0005%
4	91.5026%	7.0709%	1.3006%	0.0016%	0.0002%	0.1235%	0.0003%
5	90.9724%	7.8099%	1.0549%	0.0012%	0.0002%	0.1607%	0.0003%
6	90.7536%	8.1515%	0.8930%	0.0010%	0.0001%	0.2000%	0.0005%
7	90.8380%	8.1548%	0.7774%	0.0008%	0.0001%	0.2280%	0.0006%
8	91.1620%	7.9042%	0.6897%	0.0007%	0.0001%	0.2420%	0.0009%
9	91.6466%	7.4871%	0.6199%	0.0006%	0.0001%	0.2442%	0.0012%
10	92.2181%	6.9794%	0.5624%	0.0005%	0.0001%	0.2376%	0.0016%

Source : préparé par l'auteur à l'aide de logiciel R CRAN

Le tableau Ci-dessus indique que la variance de l'erreur de prévision des NPL est expliquée à 91.5% à ses propres innovations de façon instantanée. Ainsi les variations des NPL dépendent des variations ROA, PCC, IPC, IPI, TMM et USD autour de 2.95%, 4.56%, 0.007%, 0.001%, 0.964% et 0.005% respectivement. A long terme, la variation des NPL est expliquée à 92.21% par ses propres innovations, et la contribution de ROA, PCC, IPC, IPI, TMM et USD se limite à 6.979%, 0.562%, 0.0005%, 0.0001%, 0.2376% et 0.0016% respectivement. (Annexe14)

Section 3 : Application du stress test sur le risque de crédit

Dans cette section, nous avons entrepris de réaliser un stress test inversé pour évaluer le risque de crédit au sein de la BFPME, suite aux mauvaises décisions prises par les responsables. Notre démarche a débuté par la création de différents scénarios résultant de l'à priori sur les hyperparamètres, suivie de l'analyse de leur incidence sur le taux des prêts non performants. L'objectif était d'évaluer l'impact des mauvaises décisions prises par le personnel de la banque sur les NPL. Ainsi, nous avons testé la capacité de résilience de la BFPME face au scénario le plus pessimiste, malgré la nature de leur activité qui se limite aux CMLT d'investissement risqué.

1. La création des scénarios de stress

Sur la base des résultats du modèle BSVAR obtenus précédemment, nous choisissons d'appliquer un choc pour simuler la réaction et la prévision des responsables de la BFPME face à l'entrée de nouvelles informations micro et macroéconomiques. Pour ce faire, nous réaliserons plusieurs simulations à priori afin de prévoir la réaction des responsables, allant de la meilleure intuition à la pire décision possible. Cela nous permettra, à chaque étape, de comprendre l'impact de ces intuitions sur le niveau des prêts non performants.

Pour déterminer l'ampleur du choc dans la distribution à priori, nous simulerons différents scénarios en faisant varier les hyperparamètres. Nous choisirons ensuite la combinaison d'hyperparamètres qui représente la pire intuition possible de la part des décideurs en termes de prise de décision. Notre procédure de choix se déroulera comme suit :

- Nous sélectionnons la distribution qui fournit la RMSE la plus élevée.
- Nous sélectionnons la distribution qui fournit la MAE la plus élevée.
- Si nous obtenons la même distribution, alors nous nous arrêtons.
- Sinon, nous choisissons la distribution qui a la densité marginale la plus faible.

En tenant compte du domaine de définition de chaque hyperparamètre, nous ferons varier les valeurs de ces derniers jusqu'à l'obtention de la pire combinaison.

- **Première simulation :**

$$\lambda_0 = \lambda_1 = (0.2, 0.25, 0.3) ; \lambda_3 = (1, 1.5, 2) ; \lambda_4 = (2, 2.5, 3) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,2	0,2	2	2	0	1	1	2.676741	_	700.4254
MAE	0,2	0,2	2	2	0	1	1	_	1.410968	700.4254

Toutefois, nous remarquons que les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous procédons à une deuxième simulation.

- **Deuxième simulation :**

$$\lambda_0 = \lambda_1 = (0.15, 0.17, 0.2) ; \lambda_3 = (2, 2.2, 2.5) ; \lambda_4 = (1.5, 1.7, 2) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,15	0,15	2.5	1.5	0	1	1	3.580804	_	753.9880
MAE	0,15	0,15	2.5	1.5	0	1	1	_	1.882709	753.9880

Pourtant, nous constatons que les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous effectuons une troisième simulation.

- **Troisième simulation :**

$$\lambda_0 = \lambda_1 = (0.1, 0.12, 0.15) ; \lambda_3 = (2, 2.5, 3) ; \lambda_4 = (1, 1.5, 2) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,1	0,1	3	1	0	1	1	6.187913	_	816.3732
MAE	0,1	0,1	3	1	0	1	1	_	2.837461	816.3732

Cependant, il est à noter que les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 atteignent leurs valeurs maximales possibles. En conséquence, nous optons pour une quatrième simulation.

- **Quatrième simulation :**

$$\lambda_0 = \lambda_1 = (0.08, 0.09, 0.1) ; \lambda_3 = (3, 4, 5) ; \lambda_4 = (0.8, 0.9, 1) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,08	0,08	5	0.8	0	1	1	7.324767	_	845.6226
MAE	0,08	0,08	5	0.8	0	1	1	_	3.238978	845.6226

Néanmoins, les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 continuent d'atteindre leurs valeurs maximales possibles. Ainsi, nous engageons une cinquième simulation.

- **Cinquième simulation :**

$$\lambda_0 = \lambda_1 = (0.06, 0.07, 0.08) ; \lambda_3 = (5, 6, 7) ; \lambda_4 = (0.6, 0.7, 0.8) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,06	0,07	7	0.6	0	1	1	7.744576	_	885.4779
MAE	0,06	0,07	7	0.6	0	1	1	_	3.376569	885.4779

Pourtant, il apparaît que les hyperparamètres λ_0 , λ_3 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous passons à une sixième simulation.

- **Sixième simulation :**

$$\lambda_0 = \lambda_1 = (0.05, 0.06, 0.07) ; \lambda_3 = (7, 9, 11) ; \lambda_4 = (0.2, 0.4, 0.6) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0,06	0,07	11	0.2	0	1	1	7.795025	—	884.8466
MAE	0,06	0,07	11	0.2	0	1	1	—	3.394653	884.8466

Les hyperparamètres λ_3 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous optons pour une septième simulation.

- **Septième simulation :**

$$\lambda_0 = \lambda_1 = (0.06, 0.07) ; \lambda_3 = (11, 13, 15, 17) ; \lambda_4 = (0.05, 0.1, 0.2) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0.06	0.07	17	0.05	0	1	1	7.801121	—	884.7688
MAE	0.06	0.07	17	0.05	0	1	1	—	3.396837	884.7688

Les hyperparamètres λ_3 et λ_4 atteignent leurs valeurs maximales possibles. Par conséquent, nous engageons une huitième simulation.

- **Huitième simulation :**

$$\lambda_0 = \lambda_1 = (0.06, 0.07) ; \lambda_3 = (17, 19, 21, 22) ;$$

$$\lambda_4 = (0.001, 0.01, 0.02, 0.03, 0.04, 0.05) ; \mu_5 = \mu_6 = 1$$

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	RMSE	MAE	logMDD
RMSE	0.06	0.07	21	0.001	0	1	1	7.801529	—	884.7636
MAE	0.06	0.07	17	0.001	0	1	1	—	3.396983	884.7636

Cette fois, les hyperparamètres λ_0 , λ_1 , λ_3 et λ_4 aboutissent à des valeurs intermédiaires. Par conséquent, nous mettons fin au processus de simulation des distributions à priori. Selon le tableau ci-dessus, nous notons que la huitième simulation nous offre le couple (RMSE, MAE) le plus élevé. (Annexe15)

$$\lambda_0 = 0.06, \lambda_1 = 0.07, \lambda_3 = 21, \lambda_4 = 0.001, \mu_5 = 1 \text{ et } \mu_6 = 1$$

2. Les résultats des scénarios d'intuition

Pendant chaque réflexion sur la prise de décision à la suite de l'entrée de nouvelles informations, nous effectuons nos estimations et prévisions pour le premier trimestre 2022. Les résultats obtenus dans le tableau ci-dessous indiquent que les hyperparamètres de la simulation S12 nous conduisent aux niveaux les plus élevés des NPL instantanément. (Annexe16)

Tableau 14 : Les résultats des simulations pour l'intuition des décideurs

	λ_0	λ_1	λ_3	λ_4	λ_5	μ_5	μ_6	EQM	MAE	LogMDD	PNL après choc
S0	1	1	0	600	0	1	1	2.065220	1.068554	449.6753	83.520267
S1	0.9	0.9	0	300	0	1	1	2.073019	1.070217	463.8065	83.523015
S2	0.7	0.7	0	100	0	1	1	2.098788	1.079721	501.2995	83.535041
S3	0.5	0.5	0	30	0	1	1	2.146183	1.115123	559.7508	83.567316
S4	0.3	0.3	1	3	0	1	1	2.362193	1.265337	639.0717	83.618620
S5	0.2	0.2	2	2	0	1	1	2.676741	1.410968	700.4254	83.766314
S6	0.15	0.15	2.5	1.5	0	1	1	3.580804	1.882709	753.9880	83.977492
S7	0.1	0.1	3	1	0	1	1	6.187913	2.837461	816.3732	84.357986
S8	0.08	0.08	5	0.8	0	1	1	7.324767	3.238978	845.6226	84.536934
S9	0.06	0.07	7	0.6	0	1	1	7.744576	3.376569	885.4779	84.657794
S10	0.06	0.07	11	0.2	0	1	1	7.795025	3.394653	884.8466	84.657868
S11	0.06	0.07	17	0.05	0	1	1	7.801121	3.396837	884.7688	84.657876
S12	0.06	0,07	21	0.001	0	1	1	7.801529	3.396983	884.7636	84.657876

Source : élaborer par l'auteur à l'aide de R-CRAN


Cela peut être atteint si les décideurs raisonnent de la façon suivante :

- $\lambda_0 = 0.06$: Selon les résultats obtenus, les décideurs ne possèdent qu'une faible confiance, seulement 6 %, dans les coefficients de la matrice des effets instantanés A_0 . Cette situation s'explique par le fait qu'ils ne comprennent pas les interactions entre les variables macroéconomiques. Cette méconnaissance peut rapidement augmenter le niveau des NPL en raison de l'octroi de crédits risqués dans des contextes non favorables et en cas de chocs économiques.
- $\lambda_1 = 0.07$: Pour cet hyperparamètre, les décideurs ont un niveau de confiance de 7 % par rapport à l'hypothèse proposée par Litterman, qui suppose que chaque variable suit une marche aléatoire. Par conséquent, les décideurs ne considèrent pas que chaque variable suit une marche aléatoire, c'est-à-dire qu'ils sont conscients que toutes les variables varient selon les mêmes tendances à court et à long terme.
- $\lambda_3 = 21$: Les résultats obtenus confirment l'importance de ce paramètre qui contrôle le taux de décroissance de la variance des données compte tenu de l'augmentation du retard. Ainsi, lorsque les décideurs considèrent que la variance se réduit suite à l'augmentation du nombre de retards, cela signifie que les variances des variables restent à un niveau élevé, même si nous disposons d'un plus grand nombre d'observations. Nous pouvons également dire que l'importance de la variance des variables ne dépend pas seulement de l'historique des données, mais aussi de différents facteurs non observables par un historique des données, et qui ne doivent pas être captés par la modélisation fréquentiste.

- $\lambda_4 = 0.001$: Ce paramètre représente l'écart type autour de la tendance déterministe, c'est-à-dire la variabilité résiduelle des données après avoir soustrait la tendance. Selon les résultats obtenus, nous remarquons que dans le cas où les responsables de la BFPME considèrent qu'il n'existe pas de variabilité résiduelle et que la tendance des NPL est statique, un choc inattendu peut même changer la tendance prévue par la modélisation.

Après avoir déterminé les différents scénarios sur la réflexion des décideurs à travers la modification des hyperparamètres à priori, nous avons effectué des prévisions pour les scénarios jusqu'à atteindre la limite de 100 % des NPL. Les résultats obtenus nous ont conduits à nous arrêter au T3 2025, car les scénarios S9, S10, S11 et S12 s'approchent de la limite de 100 % des NPL. Ensuite, les prévisions pour le T3 2025 des différents scénarios sont triées du scénario le plus optimiste au scénario le plus pessimiste, comme indiqué dans la figure ci-dessous. (Annexe17)

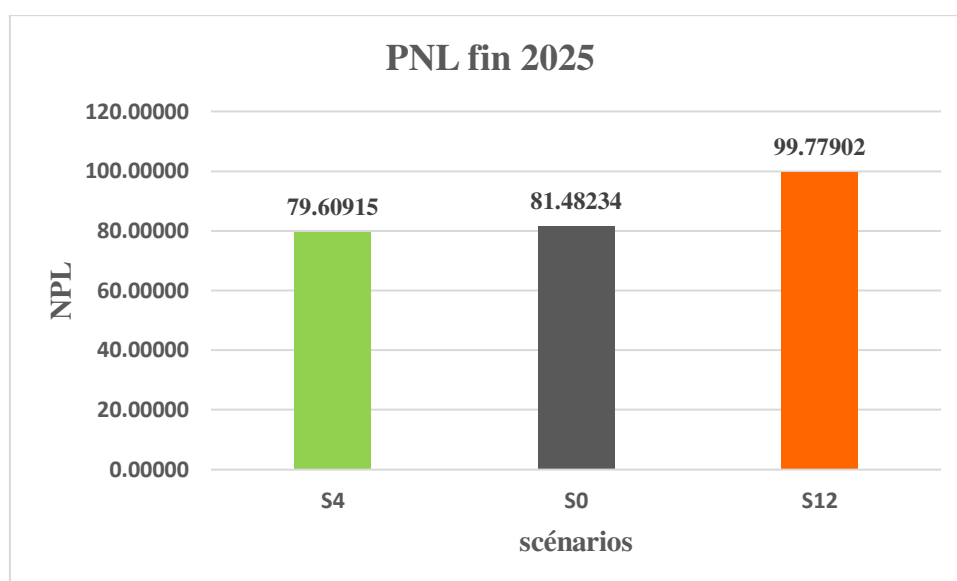
Figure 6 : Prévion des scénarios sur les NPL fin 2025



Source : élaborer par l'auteur à l'aide de l'Excel

La figure ci-dessus nous donne une idée sur le long terme : la meilleure distribution à priori n'est pas nécessairement celle qui conduit au meilleur niveau des NPL, mais plutôt à la précision des prévisions. Le graphique ci-dessous nous montre la classification des scénarios extrêmes.

Figure 7 : Préviation cas extrême sur les NPL



Source : élaborer par l'auteur à l'aide de l'Excel

Selon les résultats des prévisions des à priori des scénarios extrêmes, nous remarquons qu'à la fin de l'année 2025, la BFPME atteindra 100 % des NPL, ce qui poussera la banque vers la faillite. Cela pourrait avoir des conséquences graves sur l'écosystème en provoquant la perte d'un de ses moteurs de développement pour la création de la croissance économique et de la valeur ajoutée, ainsi que sur son rôle de réduction des tensions sociales par la création d'emplois.

3. Recommandation

3.1. Recommandation statistique

L'élément crucial de notre travail réside dans l'intégration de l'approche bayésienne pour élaborer un stress test inversé. Cela s'accomplit en appliquant un choc à la distribution à priori qui reflète la prise de décision. Notre contribution majeure consiste à répondre aux critiques formulées à l'encontre de la modélisation VECM :

- La modélisation VECM est souvent considérée comme a-théorique, ce qui peut entraîner des résultats difficiles à interpréter. Pour illustrer cette critique, prenons un exemple où le ROA de la BFPME aurait un impact sur le TMM de la BCT. Cela ne semble pas avoir de justification économique.
- Nous avons également souligné l'importance de l'intégration de l'approche bayésienne, qui enrichit le modèle en informations grâce à la distribution à priori. Cette approche a clairement amélioré la précision des prévisions, comme en témoigne l'analyse de back testing approfondie que nous avons réalisée dans la section précédente.

- L'approche fréquentiste utilise la statistique du test de Fisher avec un intervalle de confiance pouvant aller jusqu'à 10%. Cependant, cette approche s'oppose à la logique du stress test, qui doit évaluer des scénarios allant au-delà de la normale, c'est-à-dire explorer les queues de la distribution. C'est là que la statistique bayésienne se distingue, car elle se rapproche davantage de la réalité car il ne permet pas le rejet des hypothèses, ainsi qu'il autorise l'ajout des nouvelles.
- Cette nouvelle perspective du stress test est fortement recommandée pour être adoptée par le secteur bancaire, car elle permet d'évaluer l'impact des prises de décisions défavorables. Cette approche innovante remet en question l'approche traditionnelle qui repose sur l'utilisation d'un nombre arbitraire d'écart-types jusqu'à ce qu'un coefficient de solvabilité inférieur à la réglementation de la BCT soit atteint.
- L'augmentation du nombre d'écart-types basée sur la dernière observation peut entraîner une perte de la nature dynamique du modèle, sans nécessité de modifier la base de données. L'approche bayésienne offre une solution à ce problème en permettant d'appliquer des chocs à la distribution à priori.

3.2. Recommandation sur la réflexion des décideurs

Dans le cas du scénario le plus pessimiste, qui découle d'une réaction inappropriée des décideurs, il est recommandé que lors de la prise de décisions, les responsables tiennent compte des aspects suivants :

- Les responsables de la BFPME doivent construire de manière objective la matrice des effets instantanés en étudiant les causalités. Cette approche permettra de comprendre la dynamique entre les variables macroéconomiques, améliorant ainsi leurs réactions lors de l'octroi de crédits dans des contextes économiques défavorables et les incitant à plus de prudence.
- Il est nécessaire d'ajouter une tâche périodique à la direction des risques pour réaliser des stress tests. Cela permettra à la BFPME de suivre et anticiper les chocs liés à la marche aléatoire des variables. Cette approche vise à orienter les crédits accordés vers des projets financièrement résistants aux contextes économiques sensibles et aléatoires.
- Lors de la prise de décisions, la BFPME devrait s'appuyer sur des éléments subjectifs de manière scientifique, notamment dans le cadre de l'évaluation des risques liés aux crédits accordés aux promoteurs. Il est essentiel de noter que l'importance de la base de données ne permet pas nécessairement de réduire les variances des variables.

- Les décideurs sont tenus de rester vigilants et de procéder régulièrement à des tests de rétroaction (back testing) afin de se prémunir contre d'éventuelles surprises inattendues. Cette démarche leur permettra de prendre en considération toutes les éventualités pessimistes lors de l'octroi de crédits. En outre, elle contribuera à mieux anticiper la variabilité résiduelle des données après avoir soustrait la tendance.

3.3. Recommandation stratégique de la BFPME

Selon les résultats des prévisions du scénario le plus pessimiste, il est prévu que d'ici la fin de l'année 2025, l'ensemble des crédits accordés par la BFPME seront classés en tant que prêts non performants, ce qui aggraverait la situation de la banque. Pour faire face à ce problème, plusieurs recommandations stratégiques doivent être prises en compte :

- La mise en place d'un plan de restructuration qui nécessitera une recapitalisation pour sortir la banque d'une situation critique de fonds propres négatifs.
- La BFPME devra collaborer étroitement avec les acteurs de l'écosystème pour réduire le taux de mortalité des PME, tout en développant de nouveaux produits et services de financement adaptés.
- La banque pourrait chercher à attirer de nouvelles ressources non budgétaires, telles que celles provenant du FADES, QFF, BEI, BIRD, ou d'autres fonds à gérer par délégation pour le compte du secteur public et privé, y compris des fonds liés aux RSE.
- La BFPME doit améliorer la gestion des créances douteuses, ce qui lui permettra de mieux comprendre les raisons des échecs des PME et de rétablir la confiance en sa capacité à cibler efficacement et à accompagner ses promoteurs. En outre, l'ouverture de la banque à d'autres secteurs productifs en dehors de l'industrie pourrait contribuer à une meilleure gestion des risques.
- L'intégration d'un système d'information adéquat serait essentielle pour améliorer les performances de la banque et entamer sa transformation digitale.
- Une introduction en Bourse pourrait garantir une plus grande transparence et réduire l'influence politique directe. Elle faciliterait également l'accès de la banque aux marchés de capitaux, ce qui est essentiel pour son développement et sa pérennité.
- Une attention particulière doit être accordée à la composition du Conseil d'Administration et à son mode de fonctionnement, car ils semblent être en contradiction avec la stratégie de la banque et ne sont pas alignés sur les exigences de développement.

Conclusion

Ce chapitre se concentre sur une étude empirique du stress test inversé lié au risque de crédit au sein de la BFPME. Dans un premier temps, nous avons tenté d'expliquer le risque de crédit en utilisant à la fois des variables macroéconomiques et des variables spécifiques à la banque. Nous avons employé un modèle vectoriel à correction d'erreur pour cette modélisation. Cette approche nous a permis de comprendre la dynamique des variables économiques et de prévoir comment elles réagiraient face à divers chocs potentiels dans l'économie tunisienne.

Cependant, la littérature théorique et empirique met en évidence les limites de l'approche économétrique fréquentiste, qui repose entièrement sur les données historiques. Pour surmonter ces limites, des études récentes suggèrent l'intégration d'informations supplémentaires dans la modélisation, notamment à partir d'une matrice de restrictions et d'informations à priori. C'est dans ce contexte que nous avons cherché à améliorer notre étude en introduisant une distribution à priori pour la matrice des effets instantanés avant de procéder à l'estimation du modèle en question.

Dans ce cadre, pour procéder à une comparaison des performances entre le modèle VECM et le modèle BSVAR, nous avons appliqué différents tests basés sur la comparaison des prévisions. Cependant, d'après les tests nous pouvons conclure que les prévisions fournies par le modèle BSVAR sont meilleures que celles fournies par le modèle VECM.

Dans un deuxième lieu, nous avons choisi les hyperparamètres qui nous ont conduits à des réflexions problématiques de la part des décideurs lors de l'application des scénarios de stress test, afin de prévoir le niveau des prêts non performants après chaque scénario proposé. Les résultats indiquent que le niveau des prêts non performants augmente rapidement sous le scénario de stress, ce qui conduit à un taux des NPL qui atteint 100% vers la fin de l'année 2025. Cela démontre l'importance d'appliquer régulièrement des stress tests pour calibrer la réflexion des responsables et prendre des décisions en temps opportun, ce qui permet de maintenir la continuité de la banque.

CONCLUSION GENERALE

Le stress test de risque de crédit constitue un complément important aux approches quantitatives de la gestion du risque de crédit. Il permet à la fois de comprendre les modèles de risque de crédit et l'analyse des portefeuilles des banques. Le stress test fournira toujours une mesure de l'intuition qui n'est généralement pas réalisable. L'exercice de sélection des facteurs, de création de scénarios et d'évaluation de l'impact de ces scénarios induit une connexion à la fois aux modèles et aux risques du portefeuille qui est généralement beaucoup plus riche qu'avec l'analyse quantitative de portefeuille seule. Les scénarios fournissent des descriptions intuitives de certaines situations qui pourraient se produire mais qui ne se sont jamais produites auparavant, ainsi que les pertes associées à ces situations. Cela donne un aperçu à la fois du comportement du portefeuille et des facteurs du risque de crédit.

L'objectif de notre étude est, d'une part, d'intégrer l'approche structurelle et bayésienne pour modéliser le risque de crédit de la BFPME, et, d'autre part, d'utiliser les hyperparamètres de la distribution à priori dans la construction des scénarios de stress test inversé appliqués au risque de crédit. Cette étude s'articule autour de trois chapitres : le premier chapitre présente une généralité sur les risques, en mettant particulièrement l'accent sur le risque de crédit ; le deuxième chapitre traite de l'aspect théorique du stress test du risque de crédit, et le dernier chapitre a mené à la réalisation de notre étude empirique afin de montrer l'importance de l'inférence bayésienne dans l'élaboration d'un modèle du risque de crédit à travers le modèle BSVAR. Cette démarche vise à comprendre la nature de la relation entre les variables explicatives et le ratio des prêts non performants, tout en enrichissant le modèle grâce à l'aspect intuitif des décideurs.

L'étude empirique met en lumière les faiblesses de l'approche VECM, qui ne tient pas compte de l'aspect théorique des interactions entre les variables, du caractère subjectif du principe de parcimonie, et de l'acceptation des hypothèses à un intervalle de confiance de 5%, ce qui va à l'encontre de l'objectif du stress test. Pour corriger ces lacunes, nous avons tout d'abord recouru à l'intégration de la matrice des restrictions entre les variables afin de donner un sens économique à notre estimation, tout en préservant la dynamique entre les variables. De plus, nous avons également intégré l'approche bayésienne, qui permet de résoudre plusieurs problèmes, tels que la stationnarité des séries, le raisonnement en termes de plausibilité des hypothèses, ce qui nous permet de prendre en compte toutes les hypothèses sans les rejeter,

nous rapprochant ainsi au plus près de la réalité. Cela a conduit à une amélioration significative de la précision des prévisions par rapport au modèle VECM, notamment en ce qui concerne la variables NPL sur 20 périodes, passant de 14,2% à 2,3% pour l'erreur des prévisions.

Les back testing sont plus approfondis et portent sur toutes les variables sur des périodes de 10, 15 et 20 périodes pour démontrer la robustesse et la stabilité dans le temps du modèle BSVAR. Nous avons également prouvé que les différences des erreurs sont statistiquement significatives, montrant que le modèle VECM ne surpasse pas celui de BSVAR. Une idée novatrice a été d'analyser l'impact des chocs sur la réaction des décideurs face à l'entrée de nouvelles informations. En cherchant le niveau des hyperparamètres susceptibles de conduire les responsables à prendre de mauvaises décisions, nous considérons cette démarche de réflexion comme un choc extrême, et nous évaluons ses répercussions sur les NPL. L'avantage ici est de ne pas rechercher un nombre arbitraire d'écart-types.

Les résultats obtenus nous conduisent à la conclusion qu'à la fin de l'année 2025, tous les prêts de la BFPME seront qualifiés de non performants, ce qui accélérera la faillite de la banque. Pour faire face à ce problème, des recommandations ont été élaborées pour orienter les décideurs vers la prise de décisions judicieuses.

En conclusion, l'application du stress test sur le portefeuille de crédit de la banque se révèle très utile, car elle peut compléter les autres méthodes de gestion. Elle améliore la qualité des informations disponibles et éclaire les décideurs dans l'élaboration de leur stratégie, ou les aide à ajuster leurs plans d'action afin d'éviter que la banque ne subisse d'importantes pertes en cas de problèmes de gouvernance et de décisions malheureuses prises par les responsables.

Les limites de recherche :

L'une des limites de ce travail réside dans le nombre limité de variables choisi dans notre modèle, ce qui ne nous permet pas d'étudier et d'expliquer la totalité du risque de crédit. Une autre difficulté réside dans l'interprétation des hyperparamètres pour bien comprendre l'orientation de l'intuition des décideurs. De plus, nous n'avons pas calculé l'impact des NPL sur le coefficient de solvabilité de la BFPME vue l'existence d'un coefficient négatif, ainsi qu'un retard dans la clôture des années comptable. Pour mieux évaluer le choc sur le risque de crédit de la banque, il serait préférable de prendre en considération une combinaison de chocs, à la fois en termes d'écart-type et d'intuition. Il est recommandé d'intégrer d'autres risques pour généraliser le choc, tels que le risque de liquidité supporté par la banque.

BIBLIOGRAPHIE

- Adamowicz, T. (2018). Types of Risk in Banking Operations : Categorization and Definitions. *Economic and Regional Studies*, 11(4), 37--56.
- Ahmad, F., & Bashir, T. (2013). Explanatory Power of Macroeconomic Variable as Determinants of NPL: Evidence from Pakistan. *World Applied Sciences Journal*, 22, 243-255.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19, 716-723.
- Alexandri, M., & Santoso, T. (2015). Non Performing Loan : Impact of Internal and External Factor. *International Journal of Humanities and Social Science Invention*, 4(1), 87-91.
- Anand, K., Guillaume, B., & Virginie, T. (2014). Stress testing the Canadian banking System : a system-wide approach. *financial System Review*, 61-68.
- Andrea, M., Danilo, R., Nicola, P., & Tommaso, F. (2023). Advancements in Bank Stress Tests : from Bayesian Averaging to Causal AI. *Essential services for financial institutions*, 3(53), 369-388. Consulté le Mars 2023
- Audu, I. (2014). Risk management in the financial service industry. *Central Bank of Nigeria Understanding Monetary Policy Series*, 4(2), 1-34.
- Ballester , L., Ferrer, R., & González, C. (2009). interest rate risk and bank-specific characteristics. *New Frontiers in Insurance and Bank Risk Management*.
- Basel Committee on Banking Supervision. (2009). Principles for sound stress testing practices. 1-26.
- Basel Committee on Banking Supervision. (2018). *Stress testing principles*.
- Ben youcef, A. (2018). Credit Risk Stress Testing of Commercial Banks in Tunisia », , vol.1, n°1. *International Journal of Accounting and Finance Studies*, 1(1).
- Bernhard , P., & Matthieu , S. (2023, Mars 22). VAR Modelling. *Package*, 15(9), 1-52.
- BESSIS, J. (1995). *Gestion Des Risques et Gestion Actif-Passif des banques*. Paris: Dalloz.
- Blaschke, W., Jones, M., Majnoni, G., & Peria, M. (2001). Stress Testing of Financial Systems: An Overview of Issues, Methodologies, and Fsap Experiences. *IMF Working Paper*, 1(88), 1-40.

- Bolt, W., & Tieman, F. (2004). Banking Competition, Risk and Regulation. *The Scandinavian Journal of Economics*, 106(4), 783–804. Récupéré sur <http://www.jstor.org/stable/3441060>
- Bourbonnais, R. (2002). *Econométrie* (éd. 4). Paris: Dunod.
- Castro, V. (2013). Macroeconomic determinants of the credit risk in the banking system : The case of the GIPSI. *Economic Modelling*(31), 672-683.
- Chaibi, H., & Ftiti, Z. (2015). Credit risk determinants: Evidence from a cross-country study. *Research in International Business and Finance*(33), 1-16.
- Comité de Bâle sur le contrôle bancaire. (2010). Bâle III : dispositif réglementaire mondial visant à renforcer la résilience des établissements et systèmes bancaires. 1-82.
- Committee on the Global Financial System. (2005). Stress testing at major financial institutions : survey results and practice. *Bank for International Settlements*.
- Dickey, D., & Fuller, W. (1981). likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica*, 49(5), 1057–1072.
- Diebold, F., & Mariano, R. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13(3), 253-263.
- Dimitri, D. (2015). Designing Effective Macroprudential Stress Tests: Progress so Far and the Way Forward. *MF Working Paper*, 15-146. doi:<https://dx.doi.org/10.2139/ssrn.2627203>
- Dimitrios, P., Angelos, T., & Vouldis, L. (2012). Macroeconomic and bank-specific determinants of non-performing loans in Greece: A comparative study of mortgage, business and consumer loan portfolios. *Journal of Banking & Finance*, 36(4), 1012-1027. Récupéré sur <https://doi.org/10.1016/j.jbankfin.2011.10.012>.
- Engle, R., & Granger, C. (1987). Co-integrated variables and Error-correcting models : Representation, Estimation, and Testing. *Econometrica*, 55(2), 251-276.
- Fahd, N. (2013). La méthode de Denton et les comptes trimestriels. *STATECO*(107), 1-12.
- Fofack, H. (2005). Nonperforming Loans in Sub-Saharan Africa: Causal Analysis and Macroeconomic Implications. *World Bank Policy Research Working Paper*(3769), 1-36.
- Gael, M., David, T., Worapree, M., Rubén, L., Florian, H., Gary, K., . . . Anastasios, P. (2023). Bayesian forecasting in economics and finance : A modern review. *International Journal of Forecasting*. doi:ISSN 0169-2070
- Gary, K., Dimitris, K., & Davide, P. (2013). Bayesian compressed vector autoregressions. *Journal of Econometrics*, 210(1), 135-154.

- Gary, K., Dimitris, K., & Davide, P. (2019). Bayesian compressed vector autoregressions. *Journal of Econometrics*, 210(1), 135-154. doi:https://doi.org/10.1016/j.jeconom.2018.11.009
- Giudici, P., & Spelta, A. (2016). Graphical Network Models for International Financial Flows. *Journal of Business & Economic Statistics*(34), 128-138.
- Godlewski, C. (2003). Modélisation de la prévision de la défaillance bancaire une application aux banques des pays émergents. *Université Robert Schuman*, 70-98.
- Granger, C. (1969). investigating causal relations by econometrics models and cross spectral methods. *Econometrica*, 37(3), 424-438.
- Granger, C., & Newbold, P. (1986, November). Forecasting Economic Time Series. *Academic Press*(4), 352.
- Hamilton, J. (1994). *Time Series Analysis*. Princeton.
- Hannan, E., & Quinn, B. (1979). The determination of the order of an autorégression. *Journal of the Royal Statistical Society*, 41(2), 190-195.
- Harvey, D., Leybourne, S., & Newbold, P. (1998). Tests for Forecast Encompassing. *Journal of Business & Economic Statistics*, 16(2), 254-259.
- Hasan, I., & Wall, L. (2004). Determinants of the loan loss allowance: some cross-country comparison. *The Financial Review*, 39(1), 129-152.
- Hegde, S., Hegde, R., Marthanda, K., & Logu, K. (2023). Performance Analysis of Machine Learning Algorithm for the Credit Risk Analysis in the Banking Sector. *International Conference on Computing Methodologies and Communication*, 57-63.
- Jacobs, M., Ahmet, K., & Frank, J. (2015). SensenbrennerStress testing and model validation : application of the Bayesian approach to a credit risk portfolio. *The journal of risk model validation*, 9(3), 41-70.
- Jiménez, G., Lopez, J., & Saurina, J. (2013). How does competition affect bank risk-taking? *Journal of Financial Stability*, 9(2), 185-195.
- Johansen, S. (1988). Statistical Analysis of Cointegrating Vectors. *Journal of Economic Dynamics and Control*, 12(2-3), 231-254.
- Johansen, S. (1991, Nov). Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models », , , vol.59, n°6, pp.. *Econometrica*, 6(59), 1551-1580.
- Kaufman, G., & Kenneth, E. (2003). What Is Systemic Risk, and Do Bank Regulators Retard or Contribute to It ? *The Independent Review*, 3(7), 371-391.

- Kjosevski, J., Petkovski, M., & Naumovska, E. (2019). Bank-specific and macroeconomic determinants of non-performing loans in the Republic of Macedonia: Comparative analysis of enterprise and household NPLs. *Economic Research*, 1(32), 1185–1203.
- Kwiatkowski, D., Phillips, P., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root : How sure are we that economic time series have a unit root ? *Journal of Econometrics*, 3(54).
- Ličák, M. (2016). Stress testing as a risk management method. *biatec*, 3(14), 3-5.
- Lütkepohl, H. (2005). New Introduction to Multiple Time Series Analysis. *Springer-Verlag*, 764.
- Makri, V., Tsagkanos, A., & Bellas, A. (2014). Determinants of Non-Performing Loans: The Case of Eurozone. *Panoeconomicus*, 2(61), 193-206.
- Manove, M., Padilla, J., & Pagano, M. (2001). Collateral versus Project Screening: A Model of Lazy Banks. *The RAND Journal of Economics*, 32(4), 726–744. doi:<https://doi.org/10.2307/2696390>
- Mathieu, T. (2014). Implémentation du stress-test macro-prudentiel du risque de crédit bancaire dans l'Union Economique et Monétaire Ouest Africaine. *UEMOA*.
- Messai, A., & Jouini, F. (2013). Les déterminants de prêts non performants. *La Revue Gestion et Organisation*(5), 9-13.
- Messai, A., & Jouini, F. (2013). Micro and Macro Determinants of Non-performing Loans. *International Journal of Economics and Financial*, 3(4), 852–860. Récupéré sur <https://www.econjournals.com/index.php/ijefi/article/view/517>
- Moussaoui, F. (2015). Le stress test. Kolea : diplôme master statistique et économie appliqué. *Finance et actuariat*.
- Nguyên, L. (2018). *La formule du savoir : Une philosophie unifiée du savoir fondée sur le théorème de Bayes*. France: Eco science.
- Nkusu, M. (2011). Non performing Loans and Macrofinancial Vulnerabilities in Advanced. *International Monetary Fund*, 11(161), 1-27.
- Nouy, D. (2003). L'économie du nouveau dispositif et les conséquences de la nouvelle réglementation. *Revue d'économie financière*(73).
- Onha, V., Yen, V., Trang, T., & Trung, H. (2018). A Framework for Macro Stress-Testing the Credit Risk of Commercial Banks : The Case of Vietnam. *Asian Social Science*, 2(14), 1-17.
- Patrick , B., & Ryan , D. (2016, November 15). Markov-Switching, Bayesian, Vector Autoregression Models. *CRAN*, 1-92.

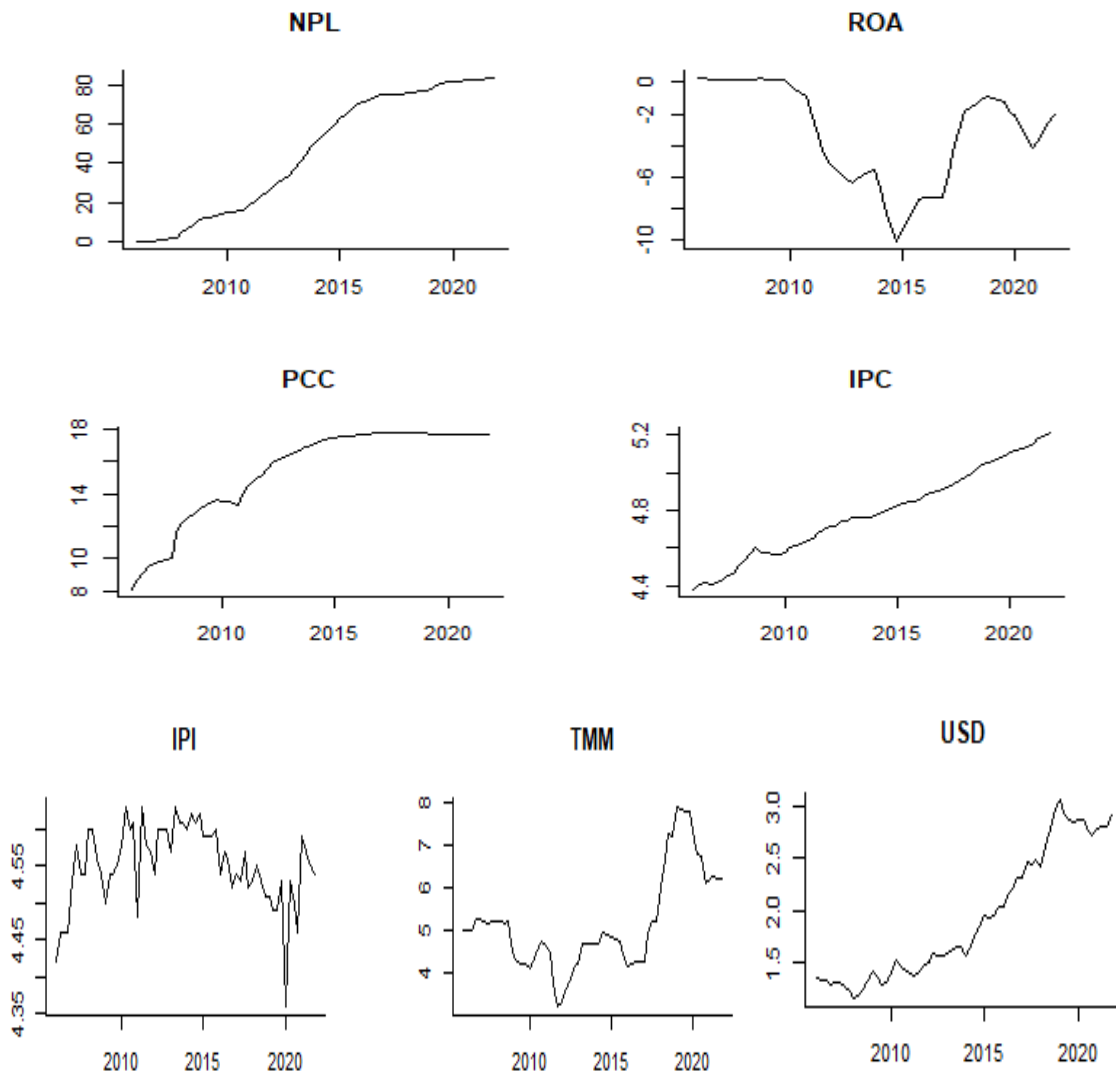
- Paul, H., Matthew, J., & Graham, S. (2004). Stress Testing Financial Systems: What to Do When the Governor Calls. *IMF Working Papers*, 38.
- Pflug, G., & Pohl, M. (2018). A Review on Ambiguity in Stochastic Portfolio Optimization. *Set-Valued Var*(26), 733–757.
- Schuermann, T. (2014). Stress testing banks. *3*(30), 717-728.
- Schwarz, G. (1978). Estimating the dimension of a model. *Annals of Statistics*, 2(6), 461-464.
- Sims, C. (1980). Macroeconomics and Reality. *Econometrica*, 1(48), 2-48.
- Sims, C., & Zha, T. (1998). Bayesian Methods for Dynamic Multivariate Models. *International Economic Review*, 4(39), 68-949.
- Spuchľáková, E., Valášková, K., & Adamko, P. (2015). The credit risk and its measurement, hedging and monitoring. *Procedia Economics and Finance*(24), 675-681.
- Sylvie, C. (2005). *Gestion de la banque du diagnostic à la stratégie* (éd. 4). Paris: Dunod.
- Taskinsoy, J. (2013). Basel III : Road to Resilient Banking. Impact on Turkey's Financial Sector. doi:978-3-659-30696-9.
- Tomasz , W. (2023, October 24). Bayesian Estimation of Structural Vector Autoregressive Models. *CRAN*, 2(1), 1-99.
- Waggoner, D., & Zha, T. (2003). a gibbs sampler for structural vector autoregressions. *Journal of Economic Dynamics and Control*, 2(28), 349–366.
- Zeman, J., & Jurca, P. (2008). Macro stress testing of the Slovak banking sector. *National bank of Slovakia working paper*.
- Zouali, N. (2015). Stress testing bancaire du risque de défaut des clients Corporate de la BMCI. *Institut national de statistique et d'économie appliquée Maroc*.

ANNEXES

Annexe 1 : Analyse descriptive

NPL		ROA		PCC		IPC	
Min.	: 0.00	Min.	: -10.090	Min.	: 8.07	Min.	: 4.380
1st Qu.	:14.43	1st Qu.	: -5.843	1st Qu.	:13.42	1st Qu.	:4.595
Median	:50.55	Median	: -2.360	Median	:16.96	Median	:4.765
Mean	:45.35	Mean	: -3.223	Mean	:15.39	Mean	:4.786
3rd Qu.	:75.45	3rd Qu.	: -0.105	3rd Qu.	:17.69	3rd Qu.	:4.965
Max.	:83.52	Max.	: 0.280	Max.	:17.77	Max.	:5.210
IPI		TMM		USD			
Min.	:4.360	Min.	:3.240	Min.	:1.167		
1st Qu.	:4.530	1st Qu.	:4.290	1st Qu.	:1.387		
Median	:4.550	Median	:4.925	Median	:1.655		
Mean	:4.551	Mean	:5.188	Mean	:1.923		
3rd Qu.	:4.600	3rd Qu.	:5.478	3rd Qu.	:2.461		
Max.	:4.630	Max.	:7.900	Max.	:3.054		

Annexe 2 : Représentation graphique



Annexe 3 : Test de la racine unitaire

1. Test de la racine unitaire I (0) :

1.1. Test ADF I (0) :

Augmented Dickey-Fuller Test	Augmented Dickey-Fuller Test
data: NPL Dickey-Fuller = -1.248, Lag order = 3, p-value = 0.8797 alternative hypothesis: stationary	data: ROA Dickey-Fuller = -1.3275, Lag order = 3, p-value = 0.8474 alternative hypothesis: stationary
Augmented Dickey-Fuller Test	Augmented Dickey-Fuller Test
data: PCC Dickey-Fuller = -1.3406, Lag order = 3, p-value = 0.8421 alternative hypothesis: stationary	data: IPC Dickey-Fuller = -3.041, Lag order = 3, p-value = 0.1531 alternative hypothesis: stationary
Augmented Dickey-Fuller Test	Augmented Dickey-Fuller Test
data: IPI Dickey-Fuller = -3.2833, Lag order = 3, p-value = 0.08236 alternative hypothesis: stationary	data: TMM Dickey-Fuller = -2.7823, Lag order = 3, p-value = 0.258 alternative hypothesis: stationary
Augmented Dickey-Fuller Test	
data: USD Dickey-Fuller = -2.1667, Lag order = 3, p-value = 0.5074 alternative hypothesis: stationary	

1.2. Test KPSS I (0) :

KPSS Test for Level Stationarity	KPSS Test for Level Stationarity
data: NPL KPSS Level = 1.6608, Truncation lag parameter = 3, p-value = 0.01	data: ROA KPSS Level = 0.52436, Truncation lag parameter = 3, p-value = 0.03618
KPSS Test for Level Stationarity	KPSS Test for Level Stationarity
data: PCC KPSS Level = 1.4589, Truncation lag parameter = 3, p-value = 0.01	data: IPC KPSS Level = 1.6779, Truncation lag parameter = 3, p-value = 0.01
KPSS Test for Level Stationarity	KPSS Test for Level Stationarity
data: IPI KPSS Level = 1.6779, Truncation lag parameter = 3, p-value = 0.01	data: TMM KPSS Level = 0.7716, Truncation lag parameter = 3, p-value = 0.01

KPSS Test for Level Stationarity

data: USD

KPSS Level = 1.5857, Truncation lag parameter = 3, p-value = 0.01

1.3.Test ADF I (1) :

Augmented Dickey-Fuller Test

data: NPL

Dickey-Fuller = -4.105, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: ROA

Dickey-Fuller = -3.815, Lag order = 3, p-value = 0.0236
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: PCC

Dickey-Fuller = -4.1979, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: IPC

Dickey-Fuller = -4.8697, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: IPI

Dickey-Fuller = -4.3978, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: TMM

Dickey-Fuller = -4.1979, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Augmented Dickey-Fuller Test

data: USD

Dickey-Fuller = -4.105, Lag order = 3, p-value = 0.01082
alternative hypothesis: stationary

1.4.Test KPSS I (1) :

KPSS Test for Level Stationarity

data: NPL

KPSS Level = 0.34661, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: ROA

KPSS Level = 0.23526, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: PCC

KPSS Level = 0.10621, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: IPC

KPSS Level = 0.063602, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: IPI

KPSS Level = 0.17489, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: TMM

KPSS Level = 0.10621, Truncation lag parameter = 3, p-value = 0.1

KPSS Test for Level Stationarity

data: USD

KPSS Level = 0.23745, Truncation lag parameter = 3, p-value = 0.1

Annexe 4 : Détermination de l'ordre de retard

```

AIC(n)  HQ(n)  SC(n)  FPE(n)
      2      1      1      2

$criteria
                1                2
AIC(n) -2.941123e+01 -2.972457e+01
HQ(n)  -2.865688e+01 -2.831018e+01
SC(n)  -2.748994e+01 -2.612217e+01
FPE(n)  1.703194e-13  1.319878e-13

AIC(n)  HQ(n)  SC(n)  FPE(n)
      2      1      1      2

$criteria
                1                2                3
AIC(n) -2.933493e+01 -2.961455e+01 -2.943279e+01
HQ(n)  -2.857547e+01 -2.819056e+01 -2.734427e+01
SC(n)  -2.739708e+01 -2.598108e+01 -2.410370e+01
FPE(n)  1.839158e-13  1.478569e-13  2.092984e-13

AIC(n)  HQ(n)  SC(n)  FPE(n)
      2      1      1      2

$criteria
                1                2                3                4
AIC(n) -2.941356e+01 -2.966619e+01 -2.949130e+01 -2.960671e+01
HQ(n)  -2.864896e+01 -2.823257e+01 -2.738865e+01 -2.683504e+01
SC(n)  -2.745884e+01 -2.600109e+01 -2.411582e+01 -2.252084e+01
FPE(n)  1.701023e-13  1.409445e-13  1.999511e-13  2.567092e-13

AIC(n)  HQ(n)  SC(n)  FPE(n)
      2      2      2      2

$criteria
                1                2                3                4                5
AIC(n) -1.124029e+02 -Inf -Inf -Inf -Inf
HQ(n)  -1.129031e+02 -Inf -Inf -Inf -Inf
SC(n)  -1.099693e+02 -Inf -Inf -Inf -Inf
FPE(n)  6.385015e-49      0      0      0      0

```

Annexe 5 : Test de cointégration

```

#####
# Johansen-Procedure #
#####

Test type: maximal eigenvalue statistic (lambda max) , with linear trend

Eigenvalues (lambda):
[1] 0.544054020 0.421460405 0.332606525 0.219479818 0.184116794 0.147899545 0.001378026

Values of teststatistic and critical values of test:

      test 10pct  5pct  1pct
r <= 6 | 0.09  6.50  8.18 11.65
r <= 5 | 9.92 12.91 14.90 19.19
r <= 4 | 12.62 18.90 21.07 25.75
r <= 3 | 15.36 24.78 27.14 32.14
r <= 2 | 25.07 30.84 33.32 38.78
r <= 1 | 33.93 36.25 39.43 44.59
r = 0  | 48.69 42.06 44.91 51.30

```

Annexe 6 : Estimation du modèle VECM

#####

###Model VECM

#####

Full sample size: 64 End sample size: 61

Number of variables: 7 Number of estimated slope parameters 112

AIC -1755.121 BIC -1506.038 SSR 30.06115

Cointegrating vector (estimated by ML):

	NPL	ROA	PCC	IPC	IPI	TMM	USD
r1	1	2.413933	-7.417291	160.742	-368.5559	-5.330123	-88.61294

	ECT	Intercept	NPL -1	ROA -1	PCC -1	IPC -1	IPI -1
Equation NPL	-0.0154(0.0093)	-17.8380(10.8656)	0.6649(0.1861)***	0.0589(0.1694)	0.4426(0.4585)	-3.5091(7.8041)	-5.0656(2.9532).
Equation ROA	0.0027(0.0083)	3.1532(9.7662)	0.0659(0.1672)	0.7505(0.1522)***	-0.0160(0.4121)	-3.5627(7.0144)	1.1761(2.6544)
Equation PCC	0.0007(0.0042)	0.9036(4.8644)	-0.0109(0.0833)	0.0118(0.0758)	0.3483(0.2053).	-0.5863(3.4938)	-0.5612(1.3221)
Equation IPC	-0.0006(0.0002)***	-0.7458(0.2079)***	-0.0078(0.0036)*	-0.0007(0.0032)	0.0161(0.0088).	0.0717(0.1493)	-0.1189(0.0565)*
Equation IPI	0.0015(0.0007)*	1.8385(0.7863)*	0.0087(0.0135)	0.0036(0.0123)	0.0074(0.0332)	0.0681(0.5647)	-0.4160(0.2137).
Equation TMM	0.0005(0.0051)	0.5891(5.9179)	-0.0312(0.1013)	0.0838(0.0922)	-0.0982(0.2497)	5.7843(4.2504)	-0.6256(1.6084)
Equation USD	0.0023(0.0012).	2.7171(1.3881).	-0.0289(0.0238)	-0.0169(0.0216)	-0.0504(0.0586)	2.7593(0.9970)**	0.4544(0.3773)
	TMM -1	USD -1	NPL -2	ROA -2	PCC -2	IPC -2	IPI -2
Equation NPL	0.4064(0.2953)	-2.2395(1.1610).	0.0709(0.1775)	-0.2298(0.1777)	0.3629(0.4332)	-4.8322(7.6651)	-2.7580(1.8535)
Equation ROA	-0.0746(0.2654)	0.6732(1.0435)	-0.0917(0.1595)	-0.1079(0.1597)	-0.1089(0.3894)	6.7203(6.8896)	0.4650(1.6659)
Equation PCC	0.0799(0.1322)	-0.5017(0.5198)	0.0102(0.0795)	-0.0588(0.0795)	0.0376(0.1940)	2.4530(3.4316)	-0.9202(0.8298)
Equation IPC	-0.0029(0.0057)	-0.0271(0.0222)	0.0012(0.0034)	0.0006(0.0034)	0.0125(0.0083)	0.0568(0.1467)	-0.0588(0.0355)
Equation IPI	0.0211(0.0214)	0.0871(0.0840)	-0.0087(0.0128)	-0.0132(0.0129)	-0.0012(0.0314)	-1.5007(0.5547)**	-0.2900(0.1341)*
Equation TMM	0.3213(0.1608).	0.3791(0.6323)	-0.0008(0.0967)	0.0210(0.0968)	0.1174(0.2360)	-6.1089(4.1748)	-1.3766(1.0095)
Equation USD	0.0862(0.0377)*	0.2481(0.1483)	0.0536(0.0227)*	0.0011(0.0227)	-0.0215(0.0553)	-0.1976(0.9792)	0.0252(0.2368)
	TMM -2	USD -2					
Equation NPL	0.1652(0.2976)	-1.9736(1.2151)					
Equation ROA	0.0593(0.2675)	1.1521(1.0921)					
Equation PCC	0.0293(0.1332)	-0.5335(0.5440)					
Equation IPC	-0.0023(0.0057)	-0.0690(0.0233)**					
Equation IPI	0.0103(0.0215)	0.0231(0.0879)					
Equation TMM	0.0798(0.1621)	0.1714(0.6618)					
Equation USD	0.0567(0.0380)	0.0350(0.1552)					

Annexe 7 : Test de validation

1. Test de stationnarité des résidus :

Group unit root test: Summary
 Series: RESID01, RESID02, RESID03, RESID04, RESID05, RESID06,
 RESID07
 Date: 11/09/23 Time: 12:03
 Sample: 2006Q1 2021Q4
 Exogenous variables: Individual effects
 Automatic selection of maximum lags
 Automatic lag length selection based on AIC: 0 to 3
 Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross-sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-15.4464	0.0000	7	412
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-15.5606	0.0000	7	412
ADF - Fisher Chi-square	208.167	0.0000	7	412
PP - Fisher Chi-square	274.631	0.0000	7	420

2. Test de normalité des résidus :

Component	Jarque-Bera	df	Prob.
1	23.33539	2	0.1152
2	371.8271	2	0.5428
3	19.86124	2	0.0875
4	6.266946	2	0.0935
5	26.08439	2	0.7712
6	0.188982	2	0.9098
7	2.049574	2	0.3589
Joint	449.6136	14	0.0000

3. Test d'hétéroscédasticité

VEC Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)
 Date: 11/09/23 Time: 12:32
 Sample: 2006Q1 2021Q4
 Included observations: 61

Joint test:		
Chi-sq	df	Prob.
819.4265	840	0.6879

4. Autocorrélation des résidus

VEC Residual Serial Correlation LM T...
 Null Hypothesis: no serial correlation ...
 Date: 11/09/23 Time: 19:32
 Sample: 2006Q1 2021Q4
 Included observations: 61

Lags	LM-Stat	Prob
1	64.49711	0.0679
2	52.52853	0.3390

Probs from chi-square with 49 df.

Annexe 8 : Test de causalité du Granger

<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:10) + Lags(NPL, 1:10)</p> <p>Model 2: ROA ~ Lags(ROA, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.4833</td> <td>0.02411 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.4833	0.02411 *	<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:10) + Lags(NPL, 1:10)</p> <p>Model 2: PCC ~ Lags(PCC, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.9822</td> <td>0.06838 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.9822	0.06838 .
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.4833	0.02411 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.9822	0.06838 .																						
<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:10) + Lags(NPL, 1:10)</p> <p>Model 2: IPC ~ Lags(IPC, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.8398</td> <td>0.0116 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.8398	0.0116 *	<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:10) + Lags(NPL, 1:10)</p> <p>Model 2: IPI ~ Lags(IPI, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.6057</td> <td>0.1484</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.6057	0.1484
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.8398	0.0116 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.6057	0.1484																						
<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:2) + Lags(NPL, 1:2)</p> <p>Model 2: TMM ~ Lags(TMM, 1:2)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>3.8432</td> <td>0.02718 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	3.8432	0.02718 *	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:10) + Lags(NPL, 1:10)</p> <p>Model 2: USD ~ Lags(USD, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.8862</td> <td>0.01056 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.8862	0.01056 *
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	3.8432	0.02718 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.8862	0.01056 *																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:20) + Lags(ROA, 1:20)</p> <p>Model 2: NPL ~ Lags(NPL, 1:20)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>23 -20</td> <td>7.3922</td> <td>0.06216 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	3			2	23 -20	7.3922	0.06216 .	<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:20) + Lags(ROA, 1:20)</p> <p>Model 2: PCC ~ Lags(PCC, 1:20)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>23 -20</td> <td>17.872</td> <td>0.01791 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	3			2	23 -20	17.872	0.01791 *
Res.Df	Df	F	Pr(>F)																						
1	3																								
2	23 -20	7.3922	0.06216 .																						
Res.Df	Df	F	Pr(>F)																						
1	3																								
2	23 -20	17.872	0.01791 *																						
<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:20) + Lags(ROA, 1:20)</p> <p>Model 2: IPC ~ Lags(IPC, 1:20)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>23 -20</td> <td>7.2888</td> <td>0.06337 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	3			2	23 -20	7.2888	0.06337 .	<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:10) + Lags(ROA, 1:10)</p> <p>Model 2: IPI ~ Lags(IPI, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.0403</td> <td>0.06059 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.0403	0.06059 .
Res.Df	Df	F	Pr(>F)																						
1	3																								
2	23 -20	7.2888	0.06337 .																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.0403	0.06059 .																						
<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:20) + Lags(ROA, 1:20)</p> <p>Model 2: TMM ~ Lags(TMM, 1:20)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>23 -20</td> <td>1.1727</td> <td>0.5185</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	3			2	23 -20	1.1727	0.5185	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:10) + Lags(ROA, 1:10)</p> <p>Model 2: USD ~ Lags(USD, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.2921</td> <td>0.03586 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.2921	0.03586 *
Res.Df	Df	F	Pr(>F)																						
1	3																								
2	23 -20	1.1727	0.5185																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.2921	0.03586 *																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:10) + Lags(PCC, 1:10)</p> <p>Model 2: NPL ~ Lags(NPL, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.1063</td> <td>0.3864</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.1063	0.3864	<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:10) + Lags(PCC, 1:10)</p> <p>Model 2: ROA ~ Lags(ROA, 1:10)</p> <table border="0" style="width: 100%;"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.1105</td> <td>0.9996</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.1105	0.9996
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.1063	0.3864																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.1105	0.9996																						

<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:10) + Lags(PCC, 1:10)</p> <p>Model 2: IPC ~ Lags(IPC, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.3877</td> <td>0.0294 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.3877	0.0294 *	<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:10) + Lags(PCC, 1:10)</p> <p>Model 2: IPI ~ Lags(IPI, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.1047</td> <td>0.05299 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.1047	0.05299 .
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.3877	0.0294 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.1047	0.05299 .																						
<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:10) + Lags(PCC, 1:10)</p> <p>Model 2: TMM ~ Lags(TMM, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.7339</td> <td>0.6877</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.7339	0.6877	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:2) + Lags(PCC, 1:2)</p> <p>Model 2: USD ~ Lags(USD, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>2.5389</td> <td>0.08785 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	2.5389	0.08785 .
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.7339	0.6877																						
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	2.5389	0.08785 .																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:10) + Lags(IPC, 1:10)</p> <p>Model 2: NPL ~ Lags(NPL, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.0793</td> <td>0.4051</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.0793	0.4051	<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:10) + Lags(IPC, 1:10)</p> <p>Model 2: ROA ~ Lags(ROA, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.4268</td> <td>0.923</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.4268	0.923
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.0793	0.4051																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.4268	0.923																						
<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:2) + Lags(IPC, 1:2)</p> <p>Model 2: PCC ~ Lags(PCC, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>0.1878</td> <td>0.8293</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	0.1878	0.8293	<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:10) + Lags(IPC, 1:10)</p> <p>Model 2: IPI ~ Lags(IPI, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.154</td> <td>0.355</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.154	0.355
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	0.1878	0.8293																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.154	0.355																						
<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:10) + Lags(IPC, 1:10)</p> <p>Model 2: TMM ~ Lags(TMM, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.8866</td> <td>0.08338 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.8866	0.08338 .	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:2) + Lags(IPC, 1:2)</p> <p>Model 2: USD ~ Lags(USD, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>4.1253</td> <td>0.02122 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	4.1253	0.02122 *
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.8866	0.08338 .																						
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	4.1253	0.02122 *																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:10) + Lags(IPI, 1:10)</p> <p>Model 2: NPL ~ Lags(NPL, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.1165</td> <td>0.3795</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.1165	0.3795	<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:10) + Lags(IPI, 1:10)</p> <p>Model 2: ROA ~ Lags(ROA, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.5768</td> <td>0.8208</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.5768	0.8208
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.1165	0.3795																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.5768	0.8208																						
<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:10) + Lags(IPI, 1:10)</p> <p>Model 2: PCC ~ Lags(PCC, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.5184</td> <td>0.1768</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.5184	0.1768	<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:8) + Lags(IPI, 1:8)</p> <p>Model 2: IPC ~ Lags(IPC, 1:8)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>39</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>47 -8</td> <td>2.1539</td> <td>0.05333 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	39			2	47 -8	2.1539	0.05333 .
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.5184	0.1768																						
Res.Df	Df	F	Pr(>F)																						
1	39																								
2	47 -8	2.1539	0.05333 .																						

<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:10) + Lags(IPI, 1:10)</p> <p>Model 2: TMM ~ Lags(TMM, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>2.3861</td> <td>0.0295 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	2.3861	0.0295 *	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:10) + Lags(IPI, 1:10)</p> <p>Model 2: USD ~ Lags(USD, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.7471</td> <td>0.6761</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.7471	0.6761
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	2.3861	0.0295 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.7471	0.6761																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:10) + Lags(TMM, 1:10)</p> <p>Model 2: NPL ~ Lags(NPL, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.2731</td> <td>0.285</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.2731	0.285	<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:2) + Lags(TMM, 1:2)</p> <p>Model 2: ROA ~ Lags(ROA, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>0.022</td> <td>0.9782</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	0.022	0.9782
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.2731	0.285																						
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	0.022	0.9782																						
<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:10) + Lags(TMM, 1:10)</p> <p>Model 2: PCC ~ Lags(PCC, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.0099</td> <td>0.4559</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.0099	0.4559	<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:20) + Lags(TMM, 1:20)</p> <p>Model 2: IPC ~ Lags(IPC, 1:20)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>23 -20</td> <td>52.123</td> <td>0.003734 **</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	3			2	23 -20	52.123	0.003734 **
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.0099	0.4559																						
Res.Df	Df	F	Pr(>F)																						
1	3																								
2	23 -20	52.123	0.003734 **																						
<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:2) + Lags(TMM, 1:2)</p> <p>Model 2: IPI ~ Lags(IPI, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>4.2481</td> <td>0.01907 *</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	4.2481	0.01907 *	<p>Granger causality test</p> <p>Model 1: USD ~ Lags(USD, 1:10) + Lags(TMM, 1:10)</p> <p>Model 2: USD ~ Lags(USD, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.6448</td> <td>0.765</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.6448	0.765
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	4.2481	0.01907 *																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.6448	0.765																						
<p>Granger causality test</p> <p>Model 1: NPL ~ Lags(NPL, 1:10) + Lags(USD, 1:10)</p> <p>Model 2: NPL ~ Lags(NPL, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.4278</td> <td>0.9224</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.4278	0.9224	<p>Granger causality test</p> <p>Model 1: ROA ~ Lags(ROA, 1:10) + Lags(USD, 1:10)</p> <p>Model 2: ROA ~ Lags(ROA, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.587</td> <td>0.8127</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.587	0.8127
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.4278	0.9224																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.587	0.8127																						
<p>Granger causality test</p> <p>Model 1: PCC ~ Lags(PCC, 1:10) + Lags(USD, 1:10)</p> <p>Model 2: PCC ~ Lags(PCC, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>1.402</td> <td>0.2225</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	1.402	0.2225	<p>Granger causality test</p> <p>Model 1: IPC ~ Lags(IPC, 1:10) + Lags(USD, 1:10)</p> <p>Model 2: IPC ~ Lags(IPC, 1:10)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>33</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>43 -10</td> <td>0.7544</td> <td>0.6697</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	33			2	43 -10	0.7544	0.6697
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	1.402	0.2225																						
Res.Df	Df	F	Pr(>F)																						
1	33																								
2	43 -10	0.7544	0.6697																						
<p>Granger causality test</p> <p>Model 1: IPI ~ Lags(IPI, 1:2) + Lags(USD, 1:2)</p> <p>Model 2: IPI ~ Lags(IPI, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>2.4226</td> <td>0.09778 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	2.4226	0.09778 .	<p>Granger causality test</p> <p>Model 1: TMM ~ Lags(TMM, 1:2) + Lags(USD, 1:2)</p> <p>Model 2: TMM ~ Lags(TMM, 1:2)</p> <table border="0"> <thead> <tr> <th>Res.Df</th> <th>Df</th> <th>F</th> <th>Pr(>F)</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>57</td> <td></td> <td></td> </tr> <tr> <td>2</td> <td>59 -2</td> <td>2.6292</td> <td>0.08087 .</td> </tr> </tbody> </table>	Res.Df	Df	F	Pr(>F)	1	57			2	59 -2	2.6292	0.08087 .
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	2.4226	0.09778 .																						
Res.Df	Df	F	Pr(>F)																						
1	57																								
2	59 -2	2.6292	0.08087 .																						

Annexe 9 : Choix de la distribution à priori

1. Simulation 1 :

lambda0	lambda1	lambda3	lambda4	lambda5	mu5
Min. :0.1	Min. :0.1	Min. :1	Min. :1	Min. :0	Min. :1
1st Qu.:0.1	1st Qu.:0.1	1st Qu.:1	1st Qu.:1	1st Qu.:0	1st Qu.:1
Median :0.2	Median :0.2	Median :2	Median :2	Median :0	Median :1
Mean :0.2	Mean :0.2	Mean :2	Mean :2	Mean :0	Mean :1
3rd Qu.:0.3	3rd Qu.:0.3	3rd Qu.:3	3rd Qu.:3	3rd Qu.:0	3rd Qu.:1
Max. :0.3	Max. :0.3	Max. :3	Max. :3	Max. :0	Max. :1

mu6	RMSE	MAE	LLF	logMDD
Min. :1	Min. :2.362	Min. :1.265	Min. :906.1	Min. :624.9
1st Qu.:1	1st Qu.:2.482	1st Qu.:1.320	1st Qu.:917.8	1st Qu.:633.2
Median :1	Median :2.899	Median :1.556	Median :975.5	Median :701.2
Mean :1	Mean :3.235	Mean :1.672	Mean :975.5	Mean :718.1
3rd Qu.:1	3rd Qu.:3.665	3rd Qu.:1.928	3rd Qu.:1037.3	3rd Qu.:818.5
Max. :1	Max. :6.188	Max. :2.837	Max. :1039.9	Max. :826.3

lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD	
[63,]	0.3	0.3	1	3	0	1	1	2.362193	1.265337	910.7073	639.0717

2. Simulation 2 :

lambda0	lambda1	lambda3	lambda4	lambda5	mu5
Min. :0.3	Min. :0.3	Min. :0.0	Min. :10	Min. :0	Min. :1
1st Qu.:0.3	1st Qu.:0.3	1st Qu.:0.0	1st Qu.:10	1st Qu.:0	1st Qu.:1
Median :0.4	Median :0.4	Median :0.5	Median :20	Median :0	Median :1
Mean :0.4	Mean :0.4	Mean :0.5	Mean :20	Mean :0	Mean :1
3rd Qu.:0.5	3rd Qu.:0.5	3rd Qu.:1.0	3rd Qu.:30	3rd Qu.:0	3rd Qu.:1
Max. :0.5	Max. :0.5	Max. :1.0	Max. :30	Max. :0	Max. :1

mu6	RMSE	MAE	LLF	logMDD
Min. :1	Min. :2.146	Min. :1.115	Min. :786.8	Min. :559.8
1st Qu.:1	1st Qu.:2.202	1st Qu.:1.162	1st Qu.:799.9	1st Qu.:564.8
Median :1	Median :2.242	Median :1.200	Median :845.8	Median :600.3
Mean :1	Mean :2.245	Mean :1.198	Mean :847.2	Mean :603.7
3rd Qu.:1	3rd Qu.:2.286	3rd Qu.:1.228	3rd Qu.:898.1	3rd Qu.:644.9
Max. :1	Max. :2.359	Max. :1.265	Max. :907.9	Max. :651.4

lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD	
[63,]	0.5	0.5	0.0	30	0	1	1	2.146183	1.115123	786.7520	559.7508

3. Simulation 3 :

lambda0	lambda1	lambda3	lambda4	lambda5	mu5
Min. :0.5	Min. :0.5	Min. :0	Min. :30.00	Min. :0	Min. :1
1st Qu.:0.5	1st Qu.:0.5	1st Qu.:0	1st Qu.:30.00	1st Qu.:0	1st Qu.:1
Median :0.6	Median :0.6	Median :0	Median :60.00	Median :0	Median :1
Mean :0.6	Mean :0.6	Mean :0	Mean :63.33	Mean :0	Mean :1
3rd Qu.:0.7	3rd Qu.:0.7	3rd Qu.:0	3rd Qu.:100.00	3rd Qu.:0	3rd Qu.:1
Max. :0.7	Max. :0.7	Max. :0	Max. :100.00	Max. :0	Max. :1

mu6	RMSE	MAE	LLF	logMDD
Min. :1	Min. :2.099	Min. :1.080	Min. :670.6	Min. :501.3
1st Qu.:1	1st Qu.:2.108	1st Qu.:1.085	1st Qu.:688.5	1st Qu.:504.6
Median :1	Median :2.120	Median :1.093	Median :726.9	Median :527.0
Mean :1	Mean :2.120	Mean :1.094	Mean :728.7	Mean :529.2
3rd Qu.:1	3rd Qu.:2.131	3rd Qu.:1.102	3rd Qu.:770.7	3rd Qu.:555.6
Max. :1	Max. :2.146	Max. :1.115	Max. :786.8	Max. :559.8

lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD	
[27,]	0.7	0.7	0	100	0	1	1	2.098788	1.079721	670.6426	501.2995

4. Simulation 4 :

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5					
Min.	:0.7	:0.7	:0	:100	:0	:1					
1st Qu.:	:0.7	:0.7	:0	:100	:0	:1					
Median :	:0.8	:0.8	:0	:200	:0	:1					
Mean :	:0.8	:0.8	:0	:200	:0	:1					
3rd Qu.:	:0.9	:0.9	:0	:300	:0	:1					
Max. :	:0.9	:0.9	:0	:300	:0	:1					
	mu6	RMSE	MAE	LLF	logMDD						
Min.	:1	:2.073	:1.070	:566.5	:463.8						
1st Qu.:	:1	:2.078	:1.072	:583.5	:464.8						
Median :	:1	:2.085	:1.074	:616.1	:480.7						
Mean :	:1	:2.085	:1.074	:618.0	:481.8						
3rd Qu.:	:1	:2.091	:1.076	:653.6	:499.7						
Max. :	:1	:2.099	:1.080	:670.6	:501.3						
	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[27,]	0.9	0.9	0	300	0	1	1	2.073019	1.070217	566.5410	463.8065

5. Simulation 5 :

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5					
Min.	:0.90	:0.90	:0	:300	:0	:1					
1st Qu.:	:0.90	:0.90	:0	:400	:0	:1					
Median :	:0.95	:0.95	:0	:600	:0	:1					
Mean :	:0.95	:0.95	:0	:600	:0	:1					
3rd Qu.:	:1.00	:1.00	:0	:800	:0	:1					
Max. :	:1.00	:1.00	:0	:900	:0	:1					
	mu6	RMSE	MAE	LLF	logMDD						
Min.	:1	:2.065	:1.069	:515.0	:449.7						
1st Qu.:	:1	:2.068	:1.069	:522.5	:449.8						
Median :	:1	:2.069	:1.069	:540.8	:456.7						
Mean :	:1	:2.069	:1.069	:540.2	:456.7						
3rd Qu.:	:1	:2.070	:1.070	:559.0	:463.6						
Max. :	:1	:2.073	:1.070	:566.5	:463.8						
	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[20,]	1.0	1.0	0	700	0	1	1	2.065220	1.068553	516.7315	449.6753

6. Simulation SZ :

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5					
Min.	:1	:0.2	:1	:1	:0	:1					
1st Qu.:	:1	:0.2	:1	:1	:0	:1					
Median :	:1	:0.2	:1	:1	:0	:1					
Mean :	:1	:0.2	:1	:1	:0	:1					
3rd Qu.:	:1	:0.2	:1	:1	:0	:1					
Max. :	:1	:0.2	:1	:1	:0	:1					
	mu6	RMSE	MAE	LLF	logMDD						
Min.	:1	:2.11	:1.157	:-13.33	:256.6						
1st Qu.:	:1	:2.11	:1.157	:-13.33	:256.6						
Median :	:1	:2.11	:1.157	:-13.33	:256.6						
Mean :	:1	:2.11	:1.157	:-13.33	:256.6						
3rd Qu.:	:1	:2.11	:1.157	:-13.33	:256.6						
Max. :	:1	:2.11	:1.157	:-13.33	:256.6						
	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[1,]	1	0.2	1	1	0	1	1	2.110103	1.156807	-13.33434	256.6349

Annexe 10 : Estimation du modèle BSVAR

 A0 restriction matrix

	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]
[1,]	1	1	0	0	0	0	0
[2,]	1	1	0	0	0	0	0
[3,]	1	1	1	0	0	0	0
[4,]	1	1	1	1	1	1	0
[5,]	0	1	1	0	1	1	1
[6,]	1	0	0	1	1	1	1
[7,]	1	1	1	1	0	0	1

 Sims-Zha Prior Bayesian Structural VAR

Prior form : Sims-Zha
 Prior hyperparameters :
 lambda0 = 1
 lambda1 = 1
 lambda3 = 0
 lambda4 = 600
 lambda5 = 0
 mu5 = 1
 mu6 = 1
 nu = 8

 Number of observations : 70
 Degrees of freedom per equation :

 Posterior Regression Coefficients :

Reduced Form Autoregressive matrices:

B(1)

	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]
[1,]	1.736834	-0.174041	-0.003353	-0.001799	-0.010556	-0.062401	-0.004814
[2,]	-0.111769	1.575906	-0.016533	-0.001934	-0.004086	0.092678	-0.016221
[3,]	-0.161613	0.348626	1.152944	0.004966	0.062755	-0.076063	0.006641
[4,]	4.097930	-1.793377	1.832395	1.218615	-0.776204	4.861661	1.155427
[5,]	-0.539242	0.176472	-0.124272	0.041613	0.479206	-0.053182	-0.077154
[6,]	0.481675	0.060217	0.035069	0.003017	-0.011765	1.266623	0.040855
[7,]	-1.452335	0.867927	-0.396766	-0.005809	-0.000195	0.174215	1.127825

B(2)

	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]
[1,]	-0.753796	0.170927	-0.000244	0.001916	0.010508	0.061467	0.006862
[2,]	0.030033	-0.667873	0.006574	0.002020	0.002418	-0.097780	0.019014
[3,]	0.219322	-0.362715	-0.156845	-0.004790	-0.062710	0.090840	-0.006176
[4,]	-4.083444	1.798058	-1.830064	-0.218660	0.776407	-4.864349	-1.156020
[5,]	0.547539	-0.177309	0.125809	-0.041246	0.519268	0.051481	0.077272
[6,]	-0.412184	-0.045470	-0.020901	-0.002465	0.010802	-0.321270	-0.049342
[7,]	1.575572	-0.725389	0.387114	0.001336	0.004631	-0.174231	-0.206207

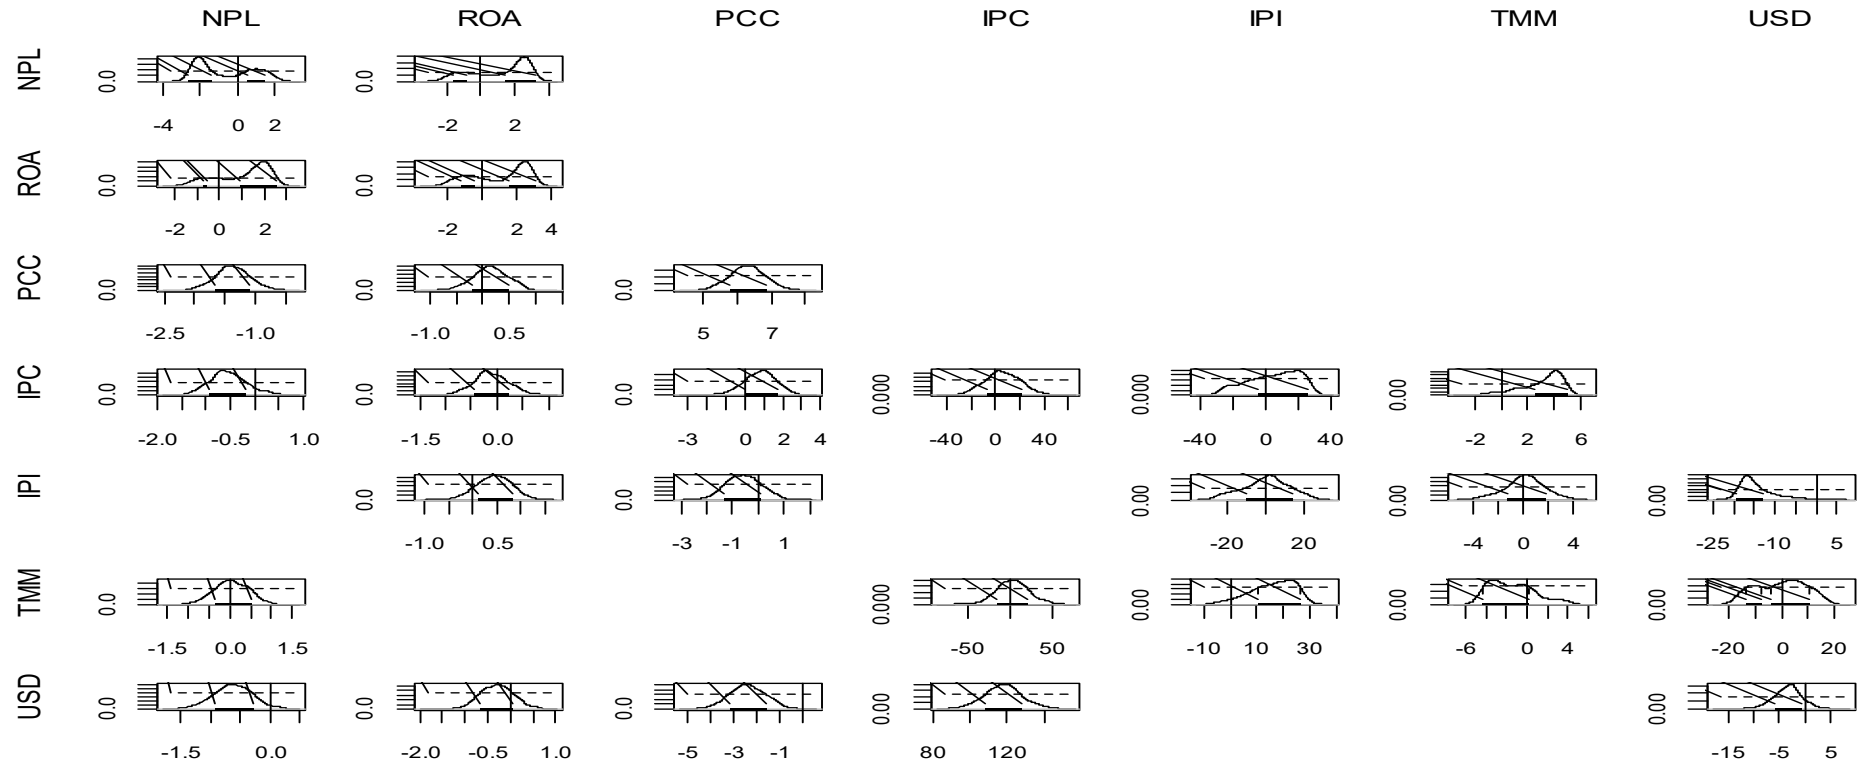
 Reduced Form Constants














































-0.755954 -0.139064 0.217674 0.008073 0.015413 0.148013 0.117875

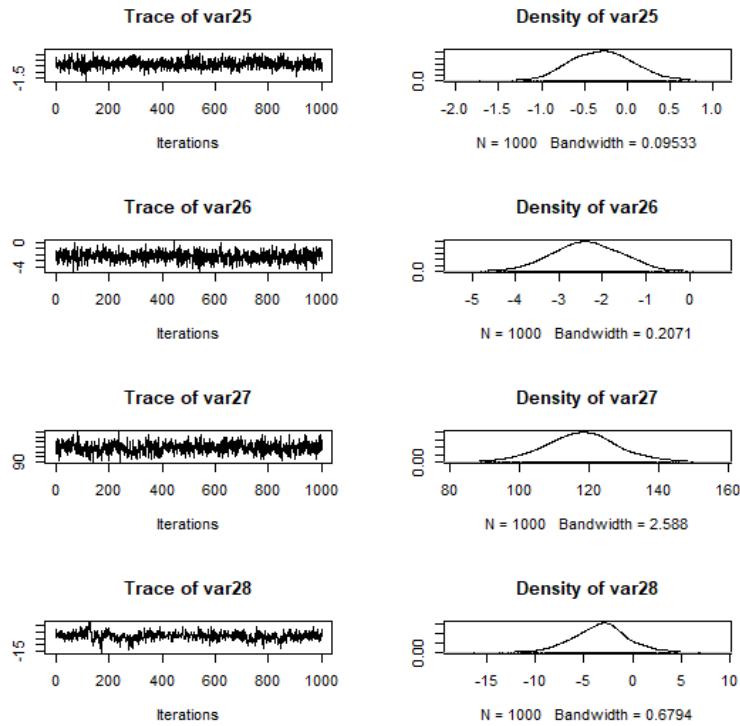
Annexe 11 : Les distributions à posteriori

```

Log prior, Pr(A0, A+)      : -133.6374
Log LLF, Pr(Y | A0, A+)    : 908.9554
Log Pr(A+|Y, A0)           : 167.0198
Log marginal density, Pr(Y) : 645.7091
Log marginal A0(k) | not A0(k) : -2.556887 -2.578695 -0.3781519 -8.16684 -6.825715 -11.20729 -5.697338
    
```







Annexe 12 : Technique de comparaison entre les deux modèles

1. Erreur quadratique moyenne de la prévision :

1.1 VECM (10 Période) :

\$NPL	\$ROA	\$PCC	\$IPC
fcst	fcst	fcst	fcst
[1,] 80.95700	[1,] -1.398734	[1,] 18.01330	[1,] 5.073878
[2,] 82.71145	[2,] -1.647274	[2,] 18.31761	[2,] 5.091008
[3,] 84.46179	[3,] -1.831730	[3,] 18.55069	[3,] 5.105476
[4,] 86.20159	[4,] -1.976168	[4,] 18.75150	[4,] 5.118938
[5,] 87.93239	[5,] -2.094523	[5,] 18.93717	[5,] 5.131617
[6,] 89.65950	[6,] -2.195970	[6,] 19.11618	[6,] 5.144072
[7,] 91.38401	[7,] -2.285950	[7,] 19.29170	[7,] 5.156353
[8,] 93.10737	[8,] -2.368183	[8,] 19.46562	[8,] 5.168587
[9,] 94.82989	[9,] -2.445032	[9,] 19.63865	[9,] 5.180783
[10,] 96.55192	[10,] -2.518133	[10,] 19.81122	[10,] 5.192969

\$IPI	\$TMM	\$USD
fcst	fcst	fcst
[1,] 4.489251	[1,] 7.927662	[1,] 2.946349
[2,] 4.484173	[2,] 7.924485	[2,] 2.987285
[3,] 4.485375	[3,] 7.926461	[3,] 3.025463
[4,] 4.483382	[4,] 7.933218	[4,] 3.060688
[5,] 4.483259	[5,] 7.953157	[5,] 3.094111
[6,] 4.482546	[6,] 7.977484	[6,] 3.126619
[7,] 4.482230	[7,] 8.006253	[7,] 3.158668
[8,] 4.481737	[8,] 8.036911	[8,] 3.190514
[9,] 4.481307	[9,] 8.069194	[9,] 3.222266
[10,] 4.480816	[10,] 8.102344	[10,] 3.253978

```

rmse <- function(error)
{
  sqrt(mean(error^2))
}

#-----#
#-----pour 10 périodes-----#
#-----#
z10<-z[1:54,]
vecm <- ca.jo(z10, type = "trace", K = 2)
sjf.var <- vec2var(vecm, r = 1)
var.fl0 <- predict(sjf.var, n.ahead = 10, ci = 0.95)

> ell10NPL<- z[55:64,1] - predicted > ell10ROA<- z[55:64,2] - predicted
> rmse(ell10NPL) > rmse(ell10ROA)
[1] 7.665065 [1] 0.9397087

> ell10PCC <- z[55:64,3] - predicted > ell10IPC<- z[55:64,4] - predicted
> rmse(ell10PCC) > rmse(ell10IPC)
[1] 1.416108 [1] 0.007905128

> ell10IPI<- z[55:64,5] - predicted > ell10TMM<- z[55:64,6] - predicted
> rmse(ell10IPI) > rmse(ell10TMM)
[1] 0.06957556 [1] 1.398864

> ell10USD<- z[55:64,7] - predicted
> rmse(ell10USD)
[1] 0.3132346

> ell10<-rmse(ell10NPL)+rmse(ell10ROA)+rmse(ell10PCC)+rmse(ell10IPC)+
+ rmse(ell10IPI)+rmse(ell10TMM)+rmse(ell10USD)
> ell10
[1] 11.81046

```

1.2 VECM (15 Période) :

```

#-----#
#-----pour 15 périodes-----#
#-----#
z15<-z[1:49,]
vecm <- ca.jo(z15, type = "trace", K = 2)
sjf.var <- vec2var(vecm, r = 1)
var.fl15 <- predict(sjf.var, n.ahead = 15, ci = 0.95)

> ell15NPL<- z[50:64,1] - predicted > ell15ROA<- z[50:64,2] - predicted
> rmse(ell15NPL) > rmse(ell15ROA)
[1] 14.21764 [1] 0.7609021

> ell15PCC <- z[50:64,3] - predicted > ell15IPC<- z[50:64,4] - predicted
> rmse(ell15PCC) > rmse(ell15IPC)
[1] 2.465816 [1] 0.01257549

> ell15IPI<- z[50:64,5] - predicted > ell15TMM<- z[50:64,6] - predicted
> rmse(ell15IPI) > rmse(ell15TMM)
[1] 0.06296937 [1] 0.8752509

> ell15USD<- z[50:64,7] - predicted
> rmse(ell15USD)
[1] 0.2523834

```

```
> e115<-rmse(e115NPL)+rmse(e115ROA)+rmse(e115PCC)+rmse(e115IPC)+
+ rmse(e115IPI)+rmse(e115TMM)+rmse(e115USD)
> e115
[1] 18.64754
```

1.3 VECM (20 Période) :

```
#-----#
#-----pour 20 périodes-----#
#-----#
z20<-z[1:44,]
vecm <- ca.jo(z20, type = "trace", K = 2)
sjf.var <- vec2var(vecm, r = 1)
var.f20 <- predict(sjf.var, n.ahead = 20, ci = 0.95)

> e120NPL<- z[45:64,1] - predicted > e120ROA<- z[45:64,2] - predicted
> rmse(e120NPL) > rmse(e120ROA)
[1] 14.21026 [1] 6.124181

> e120PCC<- z[45:64,3] - predicted > e120IPC<- z[45:64,4] - predicted
> rmse(e120PCC) > rmse(e120IPC)
[1] 2.418136 [1] 0.06186168

> e120IPI<- z[45:64,5] - predicted > e120TMM<- z[45:64,6] - predicted
> rmse(e120IPI) > rmse(e120TMM)
[1] 0.05747355 [1] 2.435553

> e120USD<- z[45:64,7] - predicted
> rmse(e120USD)
[1] 0.2587625

> e120<-rmse(e120NPL)+rmse(e120ROA)+rmse(e120PCC)+rmse(e120IPC)+
+ rmse(e120IPI)+rmse(e120TMM)+rmse(e120USD)
> e120
[1] 25.56622
```

1.4 BSVAR (10 Période) :

```
#-----#
#-----pour 10 périodes-----#
#-----#
z10 <- ts(z, start=c(2006,1),end=c(2019,2), freq=4)
fit.sbvar10 <- szbsvar(z10, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident, qm=4)
forecasts10 <- forecast(fit.sbvar10, nsteps=10)

ident <- matrix(c(1,1,0,0,0,0,0, lam0 = 1;
1,1,0,0,0,0,0, lam1 = 1;
1,1,1,0,0,0,0, lam3 = 0;
1,1,1,1,1,1,0, lam4 = 600;
0,1,1,0,1,1,1, lam5 = 0;
1,0,0,1,1,1,1, mu5 = 1;
1,1,1,1,0,0,1),7,7,byrow=T); mu6 = 1;
```

		NPL	ROA	PCC	IPC	IPI	TMM	USD
2019	Q3	80.56872	-1.618170	17.80393	5.077191	4.480398	7.894428	2.963550
2019	Q4	81.65271	-2.179313	17.85060	5.096573	4.468265	7.941209	3.032513
2020	Q1	82.66663	-2.691098	17.87984	5.116100	4.452950	7.998370	3.104567
2020	Q2	83.66891	-3.102824	17.90732	5.135186	4.438861	8.074288	3.171320
2020	Q3	84.70422	-3.401136	17.93647	5.153798	4.424834	8.162642	3.230557
2020	Q4	85.79782	-3.597324	17.96815	5.171818	4.411087	8.259271	3.282104
2021	Q1	86.95834	-3.715077	18.00144	5.189286	4.397318	8.358587	3.326939
2021	Q2	88.18242	-3.781406	18.03522	5.206306	4.383390	8.456417	3.366633
2021	Q3	89.45941	-3.820318	18.06828	5.223019	4.369168	8.549997	3.402904
2021	Q4	90.77541	-3.849619	18.09960	5.239569	4.354574	8.638132	3.437291

```

> e210NPL<- z[55:64,1] - predicted > e210ROA<- z[55:64,2] - predicted
> rmse(e210NPL) > rmse(e210ROA)
[1] 3.932113 [1] 0.8139556

> e210PCC<- z[55:64,3] - predicted > e210IPC<- z[55:64,4] - predicted
> rmse(e210PCC) > rmse(e210IPC)
[1] 0.2837072 [1] 0.02469337

> e210IPI<- z[55:64,5] - predicted > e210TMM<- z[55:64,6] - predicted
> rmse(e210IPI) > rmse(e210TMM)
[1] 0.1295857 [1] 1.701738

> e210USD<- z[55:64,7] - predicted
> rmse(e210USD)
[1] 0.4500079

> e210<-rmse(e210NPL)+rmse(e210ROA)+rmse(e210PCC)+rmse(e210IPC)+
+ rmse(e210IPI)+rmse(e210TMM)+rmse(e210USD)
> e210
[1] 7.335801

```

1.5 BSVAR (15 Période) :

```

#-----#
#-----pour 15 périodes-----#
#-----#

z15 <- ts(z, start=c(2006,1),end=c(2018,1), freq=4)
fit.sbvar15 <- szbsvar(z15, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident, qm=4)
forecasts15 <- forecast(fit.sbvar15, nsteps=15)

```

		NPL	ROA	PCC	IPC	IPI	TMM	USD
2018	Q2	76.68466	-1.860069	17.83032	5.003869	4.518101	6.371025	2.477451
2018	Q3	77.20602	-2.412963	17.84636	5.029270	4.507345	6.440466	2.540710
2018	Q4	77.34714	-3.022485	17.84941	5.056778	4.487876	6.428575	2.614283
2019	Q1	77.19874	-3.516064	17.85343	5.084787	4.471455	6.439211	2.690949
2019	Q2	76.88774	-3.798193	17.85976	5.112579	4.455875	6.499499	2.764273
2019	Q3	76.52599	-3.849615	17.87120	5.139326	4.442189	6.615596	2.829919
2019	Q4	76.18846	-3.707207	17.88781	5.164807	4.429762	6.773756	2.885982
2020	Q1	75.90968	-3.437843	17.90927	5.189180	4.418023	6.954686	2.932932
2020	Q2	75.69071	-3.113697	17.93472	5.212855	4.406330	7.139550	2.972699
2020	Q3	75.51137	-2.794919	17.96325	5.236316	4.394191	7.314324	3.007785
2020	Q4	75.34294	-2.520839	17.99414	5.259983	4.381314	7.471206	3.040525
2021	Q1	75.15837	-2.308744	18.02696	5.284142	4.367604	7.608159	3.072636
2021	Q2	74.93854	-2.157871	18.06160	5.308923	4.353120	7.727328	3.105059
2021	Q3	74.67464	-2.055938	18.09818	5.334323	4.338009	7.833085	3.138027
2021	Q4	74.36739	-1.985888	18.13699	5.360248	4.322448	7.930279	3.171262

```

> e215NPL<- z[50:64,1] - predicted > e215ROA<- z[50:64,2] - predicted
> rmse(e215NPL) > rmse(e215ROA)
[1] 5.798527 [1] 1.600362

> e215PCC<- z[50:64,3] - predicted > e215IPC<- z[50:64,4] - predicted
> rmse(e215PCC) > rmse(e215IPC)
[1] 0.2641683 [1] 0.09393881

> e215IPI<- z[50:64,5] - predicted > e215TMM<- z[50:64,6] - predicted
> rmse(e215IPI) > rmse(e215TMM)
[1] 0.1269693 [1] 1.146499

> e215USD<- z[50:64,7] - predicted
> rmse(e215USD)
[1] 0.247186

> e215<-rmse(e215NPL)+rmse(e215ROA)+rmse(e215PCC)+rmse(e215IPC)+
+ rmse(e215IPI)+rmse(e215TMM)+rmse(e215USD)
> e215
[1] 9.277651

```

1.6 BSVAR (20 Période) :

```

#-----#
#-----pour 20 périodes-----#
#-----#
z20 <- ts(z, start=c(2006,1),end=c(2016,4), freq=4)
fit.sbvar20 <- szbsvar(z20, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident, qm=4)
forecasts20 <- forecast(fit.sbvar20, nsteps=20)

```

		NPL	ROA	PCC	IPC	IPI	TMM	USD
2017	Q1	75.52055	-7.289563	17.68316	4.905344	4.524434	4.268548	2.407861
2017	Q2	76.16900	-7.411818	17.59515	4.913822	4.507519	4.237522	2.487595
2017	Q3	76.70070	-7.565162	17.52046	4.922543	4.498021	4.225927	2.572305
2017	Q4	77.13876	-7.710006	17.44028	4.931730	4.486553	4.221864	2.657515
2018	Q1	77.51662	-7.822304	17.35888	4.940740	4.475953	4.232857	2.741431
2018	Q2	77.86005	-7.893440	17.27606	4.949413	4.465520	4.255274	2.822315
2018	Q3	78.18550	-7.925968	17.19286	4.957639	4.455421	4.284794	2.899703
2018	Q4	78.49810	-7.928607	17.10925	4.965418	4.445497	4.315963	2.973758
2019	Q1	78.79421	-7.911816	17.02498	4.972802	4.435658	4.344392	3.045029
2019	Q2	79.06504	-7.884764	16.93960	4.979867	4.425817	4.367294	3.114158
2019	Q3	79.30026	-7.853806	16.85268	4.986682	4.415933	4.383617	3.181699
2019	Q4	79.49067	-7.822239	16.76394	4.993302	4.405995	4.393663	3.248024
2020	Q1	79.62974	-7.790864	16.67326	4.999756	4.396025	4.398548	3.313311
2020	Q2	79.71397	-7.758908	16.58069	5.006054	4.386056	4.399678	3.377575
2020	Q3	79.74262	-7.724938	16.48639	5.012191	4.376129	4.398358	3.440726
2020	Q4	79.71688	-7.687558	16.39062	5.018157	4.366281	4.395572	3.502626
2021	Q1	79.63911	-7.645819	16.29367	5.023937	4.356543	4.391917	3.563134
2021	Q2	79.51212	-7.599342	16.19583	5.029523	4.346936	4.387656	3.622133
2021	Q3	79.33871	-7.548266	16.09739	5.034908	4.337477	4.382816	3.679538
2021	Q4	79.12148	-7.493087	15.99861	5.040093	4.328176	4.377301	3.735300

```

> e220NPL<- z[45:64,1] - predicted > e220ROA<- z[45:64,2] - predicted
> rmse(e220NPL) > rmse(e220ROA)
[1] 2.26519 [1] 5.470359

```

```

> e220PCC<- z[45:64,3] - predicted
> rmse (e220PCC)
[1] 0.9714839

> e220IPI<- z[45:64,5] - predicted
> rmse (e220IPI)
[1] 0.12202

> e220USD<- z[45:64,7] - predicted
> rmse (e220USD)
[1] 0.492289

> e220<-rmse (e220NPL)+rmse (e220ROA)+rmse (e220PCC)+rmse (e220IPC)+
+ rmse (e220IPI)+rmse (e220TMM)+rmse (e220USD)
> e220
[1] 11.81065

> rmse (e110NPL)-rmse (e210NPL) > rmse (e115NPL)-rmse (e215NPL) > rmse (e120NPL)-rmse (e220NPL)
[1] 3.732952 [1] 8.419115 [1] 11.94507
> rmse (e110ROA)-rmse (e210ROA) > rmse (e115ROA)-rmse (e215ROA) > rmse (e120ROA)-rmse (e220ROA)
[1] 0.1257532 [1] -0.8394603 [1] 0.6538219
> rmse (e110PCC)-rmse (e210PCC) > rmse (e115PCC)-rmse (e215PCC) > rmse (e120PCC)-rmse (e220PCC)
[1] 1.132401 [1] 2.201648 [1] 1.446652
> rmse (e110IPC)-rmse (e210IPC) > rmse (e115IPC)-rmse (e215IPC) > rmse (e120IPC)-rmse (e220IPC)
[1] -0.01678824 [1] -0.08136332 [1] -0.03543353
> rmse (e110IPI)-rmse (e210IPI) > rmse (e115IPI)-rmse (e215IPI) > rmse (e120IPI)-rmse (e220IPI)
[1] -0.06001012 [1] -0.06399991 [1] -0.06454641
> rmse (e110TMM)-rmse (e210TMM) > rmse (e115TMM)-rmse (e215TMM) > rmse (e120TMM)-rmse (e220TMM)
[1] -0.3028746 [1] -0.2712481 [1] 0.04354216
> rmse (e110USD)-rmse (e210USD) > rmse (e115USD)-rmse (e215USD) > rmse (e120USD)-rmse (e220USD)
[1] -0.1367733 [1] 0.005197314 [1] -0.2335264
> e110-e210 > e115-e215 > e120-e220
[1] 4.47466 [1] 9.369888 [1] 13.75558

```

2. Test de Diebold-Mariano :

```

> DM10
      d10NPL      d10ROA      d10PCC      d10IPC      d10IPI      d10TMM      d10USD
-10.307609 -1.336901 -13.183107  11.420819   8.466076  10.575518  14.098542

> DM15
      d15NPL      d15ROA      d15PCC      d15IPC      d15IPI      d15TMM      d15USD
-16.2515487  12.3929002 -21.9787501  16.5904678  10.9478409   6.3178488  -0.4463868

> DM20
      d20NPL      d20ROA      d20PCC      d20IPC      d20IPI      d20TMM      d20USD
-16.835644 -11.350612 -18.349833  15.970442  10.842932  -6.398287   8.638045

```

3. Test de la dominance de prévision :

```

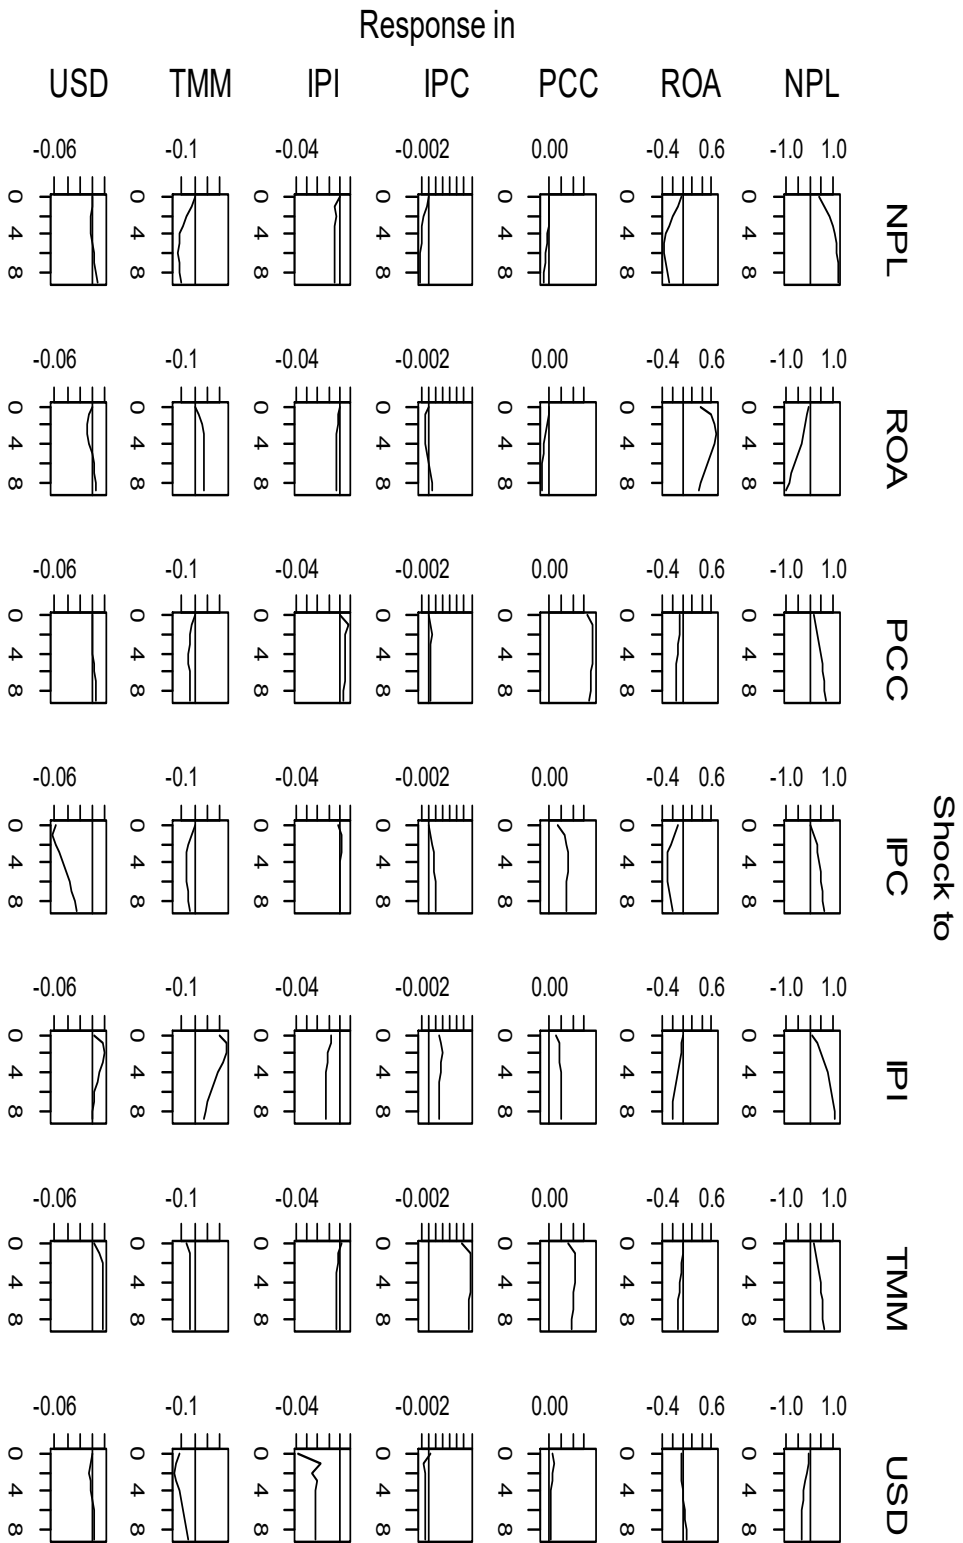
> DP10
      f10NPL      f10ROA      f10PCC      f10IPC      f10IPI      f10TMM      f10USD
  6.763253   5.429815   8.039620  -6.977208  -5.468527  -8.655040 -10.022425

> DP15
      f15NPL      f15ROA      f15PCC      f15IPC      f15IPI      f15TMM      f15USD
  9.717667 -8.946736  12.421975 -7.399985 -7.048596   7.136566   8.010206

> DP20
      f20NPL      f20ROA      f20PCC      f20IPC      f20IPI      f20TMM      f20USD
 1.146090e+01  1.155520e+01  1.236499e+01 -8.921245e+05 -2.638759e+05 -3.973467e+00 -1.794513e+03

```

Annexe 13 : Les fonctions d'impulsion



Annexe 14 : Décomposition de la variance de NPL

Decomposition of Forecast Errors for a Shock to NPL

	Std. Error	NPL	ROA	PCC	IPC	IPI	TMM	USD
[1,]	0.5081069	91.50263	2.953268	4.5647732	0.0073279322	0.0019877161	0.9649047	0.0051067760
[2,]	1.0410129	92.68549	4.488509	2.5300832	0.0036646430	0.0004802354	0.2905074	0.0012604335
[3,]	1.6057184	92.21998	5.932743	1.7150463	0.0022833454	0.0003021533	0.1290939	0.0005522115
[4,]	2.1741865	91.50267	7.070925	1.3006090	0.0016211883	0.0002559302	0.1235330	0.0003811296
[5,]	2.7308158	90.97245	7.809941	1.0549965	0.0012504366	0.0002228742	0.1607520	0.0003920483
[6,]	3.2676102	90.75363	8.151537	0.8930272	0.0010182412	0.0001949570	0.2000886	0.0005046874
[7,]	3.7813303	90.83803	8.154811	0.7774180	0.0008599444	0.0001734373	0.2280134	0.0006907134
[8,]	4.2714831	91.16207	7.904299	0.6897107	0.0007448692	0.0001587747	0.2420772	0.0009380794
[9,]	4.7388396	91.64663	7.487172	0.6199487	0.0006572167	0.0001507503	0.2442008	0.0012439797
[10,]	5.1844325	92.21812	6.979460	0.5624351	0.0005883046	0.0001490257	0.2376355	0.0016121569

Annexe 15 : Choix de scénario du stress

1. Simulation 1 :

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5					
Min.	:0.20	Min. :0.20	Min. :1.0	Min. :2.0	Min. :0	Min. :1					
1st Qu.:	:0.20	1st Qu. :0.20	1st Qu. :1.0	1st Qu. :2.0	1st Qu. :0	1st Qu. :1					
Median :	:0.25	Median :0.25	Median :1.5	Median :2.5	Median :0	Median :1					
Mean :	:0.25	Mean :0.25	Mean :1.5	Mean :2.5	Mean :0	Mean :1					
3rd Qu.:	:0.30	3rd Qu. :0.30	3rd Qu. :2.0	3rd Qu. :3.0	3rd Qu. :0	3rd Qu. :1					
Max. :	:0.30	Max. :0.30	Max. :2.0	Max. :3.0	Max. :0	Max. :1					
	mu6	RMSE	MAE	LLF	logMDD						
Min. :	:1	Min. :2.362	Min. :1.264	Min. :907.4	Min. :628.0						
1st Qu.:	:1	1st Qu. :2.422	1st Qu. :1.289	1st Qu. :913.5	1st Qu. :633.9						
Median :	:1	Median :2.459	Median :1.297	Median :941.9	Median :662.4						
Mean :	:1	Mean :2.473	Mean :1.307	Mean :942.5	Mean :665.7						
3rd Qu.:	:1	3rd Qu. :2.517	3rd Qu. :1.319	3rd Qu. :972.4	3rd Qu. :699.8						
Max. :	:1	Max. :2.677	Max. :1.411	Max. :976.2	Max. :705.5						
	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[19,]	0.20	0.20	2.0	2.0	0	1	1	2.676741	1.410968	975.4739	700.4254

2. Simulation 2 :

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5					
Min.	:0.1500	Min. :0.1500	Min. :2.000	Min. :1.500	Min. :0	Min. :1					
1st Qu.:	:0.1500	1st Qu. :0.1500	1st Qu. :2.000	1st Qu. :1.500	1st Qu. :0	1st Qu. :1					
Median :	:0.1700	Median :0.1700	Median :2.200	Median :1.700	Median :0	Median :1					
Mean :	:0.1733	Mean :0.1733	Mean :2.233	Mean :1.733	Mean :0	Mean :1					
3rd Qu.:	:0.2000	3rd Qu. :0.2000	3rd Qu. :2.500	3rd Qu. :2.000	3rd Qu. :0	3rd Qu. :1					
Max. :	:0.2000	Max. :0.2000	Max. :2.500	Max. :2.000	Max. :0	Max. :1					
	mu6	RMSE	MAE	LLF	logMDD						
Min. :	:1	Min. :2.677	Min. :1.411	Min. : 975.3	Min. :699.8						
1st Qu.:	:1	1st Qu. :2.848	1st Qu. :1.524	1st Qu. : 976.5	1st Qu. :701.6						
Median :	:1	Median :3.019	Median :1.618	Median : 995.2	Median :731.0						
Mean :	:1	Mean :3.060	Mean :1.632	Mean : 993.0	Mean :728.5						
3rd Qu.:	:1	3rd Qu. :3.271	3rd Qu. :1.746	3rd Qu. :1007.6	3rd Qu. :753.2						
Max. :	:1	Max. :3.581	Max. :1.883	Max. :1007.9	Max. :754.3						
	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[19,]	0.15	0.15	2.5	1.5	0	1	1	3.580804	1.882709	1007.6100	753.9880

3. Simulation 3 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.1000	Min.	:0.1000	Min.	:2.0	Min.	:1.0	Min.	:0	Min.	:1
1st Qu.:	:0.1000	1st Qu.:	:0.1000	1st Qu.:	:2.0	1st Qu.:	:1.0	1st Qu.:	:0	1st Qu.:	:1
Median	:0.1200	Median	:0.1200	Median	:2.5	Median	:1.5	Median	:0	Median	:1
Mean	:0.1233	Mean	:0.1233	Mean	:2.5	Mean	:1.5	Mean	:0	Mean	:1
3rd Qu.:	:0.1500	3rd Qu.:	:0.1500	3rd Qu.:	:3.0	3rd Qu.:	:2.0	3rd Qu.:	:0	3rd Qu.:	:1
Max.	:0.1500	Max.	:0.1500	Max.	:3.0	Max.	:2.0	Max.	:0	Max.	:1
mu6		RMSE		MAE		LLF		logMDD			
Min.	:1	Min.	:3.495	Min.	:1.849	Min.	:1006	Min.	:752.3		
1st Qu.:	:1	1st Qu.:	:4.198	1st Qu.:	:2.126	1st Qu.:	:1008	1st Qu.:	:754.1		
Median	:1	Median	:4.744	Median	:2.338	Median	:1026	Median	:790.9		
Mean	:1	Mean	:4.772	Mean	:2.331	Mean	:1024	Mean	:788.0		
3rd Qu.:	:1	3rd Qu.:	:5.333	3rd Qu.:	:2.538	3rd Qu.:	:1038	3rd Qu.:	:817.9		
Max.	:1	Max.	:6.188	Max.	:2.837	Max.	:1039	Max.	:822.4		

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[19,]	0.10	0.10	3.0	1.0	0	1	1	6.187913	2.837461	1037.198	816.3732

4. Simulation 4 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.08	Min.	:0.08	Min.	:3	Min.	:0.8	Min.	:0	Min.	:1
1st Qu.:	:0.08	1st Qu.:	:0.08	1st Qu.:	:3	1st Qu.:	:0.8	1st Qu.:	:0	1st Qu.:	:1
Median	:0.09	Median	:0.09	Median	:4	Median	:0.9	Median	:0	Median	:1
Mean	:0.09	Mean	:0.09	Mean	:4	Mean	:0.9	Mean	:0	Mean	:1
3rd Qu.:	:0.10	3rd Qu.:	:0.10	3rd Qu.:	:5	3rd Qu.:	:1.0	3rd Qu.:	:0	3rd Qu.:	:1
Max.	:0.10	Max.	:0.10	Max.	:5	Max.	:1.0	Max.	:0	Max.	:1
mu6		RMSE		MAE		LLF		logMDD			
Min.	:1	Min.	:6.188	Min.	:2.837	Min.	:1037	Min.	:812.6		
1st Qu.:	:1	1st Qu.:	:6.560	1st Qu.:	:2.971	1st Qu.:	:1037	1st Qu.:	:815.9		
Median	:1	Median	:6.828	Median	:3.066	Median	:1043	Median	:830.1		
Mean	:1	Mean	:6.800	Mean	:3.055	Mean	:1043	Mean	:830.7		
3rd Qu.:	:1	3rd Qu.:	:7.053	3rd Qu.:	:3.144	3rd Qu.:	:1049	3rd Qu.:	:846.3		
Max.	:1	Max.	:7.325	Max.	:3.239	Max.	:1050	Max.	:849.1		

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[19,]	0.08	0.08	5	0.8	0	1	1	7.324767	3.238978	1049.426	845.6226

5. Simulation 5 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.06	Min.	:0.06	Min.	:5	Min.	:0.6	Min.	:0	Min.	:1
1st Qu.:	:0.06	1st Qu.:	:0.06	1st Qu.:	:5	1st Qu.:	:0.6	1st Qu.:	:0	1st Qu.:	:1
Median	:0.07	Median	:0.07	Median	:6	Median	:0.7	Median	:0	Median	:1
Mean	:0.07	Mean	:0.07	Mean	:6	Mean	:0.7	Mean	:0	Mean	:1
3rd Qu.:	:0.08	3rd Qu.:	:0.08	3rd Qu.:	:7	3rd Qu.:	:0.8	3rd Qu.:	:0	3rd Qu.:	:1
Max.	:0.08	Max.	:0.08	Max.	:7	Max.	:0.8	Max.	:0	Max.	:1
mu6		RMSE		MAE		LLF		logMDD			
Min.	:1	Min.	:7.325	Min.	:3.239	Min.	:1049	Min.	:842.4		
1st Qu.:	:1	1st Qu.:	:7.553	1st Qu.:	:3.317	1st Qu.:	:1050	1st Qu.:	:845.0		
Median	:1	Median	:7.663	Median	:3.349	Median	:1055	Median	:863.6		
Mean	:1	Mean	:7.614	Mean	:3.334	Mean	:1055	Mean	:864.5		
3rd Qu.:	:1	3rd Qu.:	:7.699	3rd Qu.:	:3.360	3rd Qu.:	:1060	3rd Qu.:	:885.3		
Max.	:1	Max.	:7.745	Max.	:3.377	Max.	:1061	Max.	:886.8		

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[22,]	0.06	0.07	7	0.6	0	1	1	7.744576	3.376569	1060.465	885.4779

6. Simulation 6 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.05	Min.	:0.05	Min.	: 7	Min.	:0.2	Min.	:0	Min.	:1
1st Qu.	:0.05	1st Qu.	:0.05	1st Qu.	: 7	1st Qu.	:0.2	1st Qu.	:0	1st Qu.	:1
Median	:0.06	Median	:0.06	Median	: 9	Median	:0.4	Median	:0	Median	:1
Mean	:0.06	Mean	:0.06	Mean	: 9	Mean	:0.4	Mean	:0	Mean	:1
3rd Qu.	:0.07	3rd Qu.	:0.07	3rd Qu.	:11	3rd Qu.	:0.6	3rd Qu.	:0	3rd Qu.	:1
Max.	:0.07	Max.	:0.07	Max.	:11	Max.	:0.6	Max.	:0	Max.	:1

mu6		RMSE		MAE		LLF		logMDD	
Min.	:1	Min.	:7.281	Min.	:3.188	Min.	:1055	Min.	:860.7
1st Qu.	:1	1st Qu.	:7.578	1st Qu.	:3.304	1st Qu.	:1056	1st Qu.	:862.5
Median	:1	Median	:7.707	Median	:3.359	Median	:1061	Median	:884.4
Mean	:1	Mean	:7.649	Mean	:3.335	Mean	:1060	Mean	:885.5
3rd Qu.	:1	3rd Qu.	:7.745	3rd Qu.	:3.374	3rd Qu.	:1064	3rd Qu.	:909.8
Max.	:1	Max.	:7.795	Max.	:3.395	Max.	:1065	Max.	:910.8

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[26,]	0.06	0.07	11	0.2	0	1	1	7.795025	3.394653	1060.308	884.8466

7. Simulation 7 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.060	Min.	:0.060	Min.	:11.0	Min.	:0.0500	Min.	:0	Min.	:1
1st Qu.	:0.060	1st Qu.	:0.060	1st Qu.	:12.5	1st Qu.	:0.0500	1st Qu.	:0	1st Qu.	:1
Median	:0.065	Median	:0.065	Median	:14.0	Median	:0.1000	Median	:0	Median	:1
Mean	:0.065	Mean	:0.065	Mean	:14.0	Mean	:0.1167	Mean	:0	Mean	:1
3rd Qu.	:0.070	3rd Qu.	:0.070	3rd Qu.	:15.5	3rd Qu.	:0.2000	3rd Qu.	:0	3rd Qu.	:1
Max.	:0.070	Max.	:0.070	Max.	:17.0	Max.	:0.2000	Max.	:0	Max.	:1

mu6		RMSE		MAE		LLF		logMDD	
Min.	:1	Min.	:7.750	Min.	:3.373	Min.	:1055	Min.	:861.4
1st Qu.	:1	1st Qu.	:7.757	1st Qu.	:3.382	1st Qu.	:1056	1st Qu.	:862.2
Median	:1	Median	:7.776	Median	:3.390	Median	:1058	Median	:873.3
Mean	:1	Mean	:7.777	Mean	:3.388	Mean	:1058	Mean	:873.2
3rd Qu.	:1	3rd Qu.	:7.799	3rd Qu.	:3.396	3rd Qu.	:1060	3rd Qu.	:884.3
Max.	:1	Max.	:7.801	Max.	:3.397	Max.	:1061	Max.	:884.8

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[15,]	0.06	0.07	17	0.05	0	1	1	7.801121	3.396837	1060.289	884.7688

8. Simulation 8 :

lambda0		lambda1		lambda3		lambda4		lambda5		mu5	
Min.	:0.060	Min.	:0.060	Min.	:17.00	Min.	:0.00100	Min.	:0	Min.	:1
1st Qu.	:0.060	1st Qu.	:0.060	1st Qu.	:18.50	1st Qu.	:0.01000	1st Qu.	:0	1st Qu.	:1
Median	:0.065	Median	:0.065	Median	:20.00	Median	:0.02500	Median	:0	Median	:1
Mean	:0.065	Mean	:0.065	Mean	:19.75	Mean	:0.02517	Mean	:0	Mean	:1
3rd Qu.	:0.070	3rd Qu.	:0.070	3rd Qu.	:21.25	3rd Qu.	:0.04000	3rd Qu.	:0	3rd Qu.	:1
Max.	:0.070	Max.	:0.070	Max.	:22.00	Max.	:0.05000	Max.	:0	Max.	:1

mu6		RMSE		MAE		LLF		logMDD	
Min.	:1	Min.	:7.757	Min.	:3.376	Min.	:1055	Min.	:861.4
1st Qu.	:1	1st Qu.	:7.758	1st Qu.	:3.384	1st Qu.	:1055	1st Qu.	:862.2
Median	:1	Median	:7.780	Median	:3.392	Median	:1058	Median	:873.2
Mean	:1	Mean	:7.780	Mean	:3.389	Mean	:1058	Mean	:873.1
3rd Qu.	:1	3rd Qu.	:7.801	3rd Qu.	:3.397	3rd Qu.	:1060	3rd Qu.	:884.2
Max.	:1	Max.	:7.802	Max.	:3.397	Max.	:1061	Max.	:884.8

	lambda0	lambda1	lambda3	lambda4	lambda5	mu5	mu6	RMSE	MAE	LLF	logMDD
[11,]	0.06	0.07	21	0.001	0	1	1	7.801529	3.396983	1060.287	884.7636

Annexe 16 : Pr evision Court Terme

```
lam0 = 1; lam1 = 1; lam3 = 0; lam4 = 600; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.52027

```
lam0 = 0.9; lam1 = 0.9; lam3 = 0; lam4 = 300; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.52302

```
lam0 = 0.7; lam1 = 0.7; lam3 = 0; lam4 = 100; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.53504

```
lam0 = 0.5; lam1 = 0.5; lam3 = 0; lam4 = 30; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.56732

```
lam0 = 0.3; lam1 = 0.3; lam3 = 1; lam4 = 3; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.61862

```
lam0 = 0.2; lam1 = 0.2; lam3 = 2; lam4 = 2; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.76631

```
lam0 = 0.15; lam1 = 0.15; lam3 = 2.5; lam4 = 1.5; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
83.97749

```
lam0 = 0.1; lam1 = 0.1; lam3 = 3; lam4 = 1; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
84.35799

```
lam0 = 0.08; lam1 = 0.08; lam3 = 5; lam4 = 0.8; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
84.53693

```
lam0 = 0.06; lam1 = 0.07; lam3 = 7; lam4 = 0.6; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
84.65779

```
lam0 = 0.06; lam1 = 0.07; lam3 = 11; lam4 = 0.2; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
84.65787

```
lam0 = 0.06; lam1 = 0.07; lam3 = 17; lam4 = 0.05; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```


NPL
84.65788

```
lam0 = 0.06; lam1 = 0.07; lam3 = 21; lam4 = 0.001; lam5 = 0; mu5 = 1; mu6 = 1;
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1,
lambda3=lam3, lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=1)
forecasts[65,1]
```

NPL
84.65788

Annexe 17 : Pr evision Long Terme

```
fit.sbvar <- szbsvar(z, p=2, z=NULL, lambda0=lam0, lambda1=lam1, lambda3=lam3,
lambda4=lam4, lambda5=lam5, mu5=mu5, mu6=mu6, ident , qm=4)
forecasts <- forecast(fit.sbvar, nsteps=16)
forecasts[,1]
```



Date	S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12
Déc-21	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000	83,52000
Mars-22	83,52027	83,52302	83,53504	83,56732	83,61862	83,76631	83,97749	84,35799	84,53693	84,65779	84,65787	84,65788	84,65788
Juin-22	83,46403	83,46936	83,49216	83,54883	83,62983	83,94870	84,38533	85,17005	85,53935	85,78830	85,78845	85,78846	85,78846
Sept-22	83,37983	83,38666	83,41543	83,48287	83,57809	84,07282	84,74506	85,95607	86,52704	86,91140	86,91163	86,91166	86,91166
Déc-22	83,26401	83,27166	83,30346	83,37479	83,47045	84,14036	85,05722	86,71585	87,49984	88,02701	88,02733	88,02736	88,02737
Mars-23	83,12031	83,12840	83,16164	83,23367	83,31082	84,15307	85,32240	87,44921	88,45757	89,13503	89,13544	89,13548	89,13548
Juin-23	82,95434	82,96273	82,99688	83,06799	83,10262	84,11277	85,54129	88,15600	89,40005	90,23536	90,23586	90,23591	90,23591
Sept-23	82,77439	82,78299	82,81757	82,88520	82,84926	84,02140	85,71465	88,83608	90,32712	91,32791	91,32850	91,32856	91,32856
Déc-23	82,58825	82,59690	82,63106	82,69095	82,55416	83,88101	85,84329	89,48934	91,23862	92,41258	92,41326	92,41333	92,41334
Mars-24	82,40274	82,41114	82,44336	82,48941	82,22077	83,69370	85,92813	90,11571	92,13442	93,48928	93,49007	93,49015	93,49015
Juin-24	82,22292	82,23062	82,25872	82,28356	81,85255	83,46169	85,97011	90,71510	93,01437	94,55793	94,55882	94,55891	94,55892
Sept-24	82,05221	82,05862	82,07994	82,07557	81,45295	83,18727	85,97029	91,28748	93,87833	95,61844	95,61944	95,61954	95,61955
Déc-24	81,89247	81,89693	81,90856	81,86705	81,02541	82,87278	85,92974	91,83283	94,72618	96,67072	96,67183	96,67194	96,67195
Mars-25	81,74442	81,74625	81,74527	81,65926	80,57334	82,52064	85,84963	92,35113	95,55779	97,71469	97,71592	97,71604	97,71605
Juin-25	81,60791	81,60648	81,59018	81,45322	80,10015	82,13330	85,73115	92,84242	96,37307	98,75028	98,75162	98,75176	98,75177
Sept-25	81,48234	81,47706	81,44309	81,24980	79,60915	81,71329	85,57559	93,30674	97,17190	99,77740	99,77886	99,77901	99,77902

Date	S4	S3	S2	S1	S0	S5	S6	S7	S8	S9	S10	S11	S12
Sept-25	79,60915	81,24980	81,44309	81,47706	81,48234	81,71329	85,57559	93,30674	97,17190	99,77740	99,77886	99,77901	99,77902

TABLE DES MATIERES

REMERCIEMENTS.....	i
DEDICACES	ii
SOMMAIRE	iv
LISTE DES ABREVIATIONS.....	v
LISTE DES TABLEAUX.....	vi
LISTE DES FIGURES.....	vii
INTRODUCTION GENERALE.....	1
CHAPITRE 1 : GENERALITE SUR LE RISQUE DU CREDIT.....	3
Introduction	4
Section 1 : Catégorisation des risques dans le secteur bancaire et analyse du risque de crédit.....	5
1. Compréhension du concept de risque.....	5
2. Typologie des risques dans le domaine bancaire.....	5
2.1. Le risque de marché.....	6
2.2. Le risque opérationnel.....	6
2.3. Risque de liquidité	7
2.4. Risque pays	7
2.5. Le risque d'insolvabilité.....	8
2.6. Risque systémique	8
3. Évaluation et gestion du risque de crédit.....	8
3.1. Définition du risque de crédit.....	9
3.2. Les Types du risque de crédit.....	9
3.2.1. Le risque de défaut	9
3.2.2. Le risque de dégradation du spread	10
3.2.3. Le risque de recouvrement.....	10
Section 2 : Les déterminants du risque de crédit.....	11
1. Facteur externe du risque de crédit.....	11
1.1. La croissance économique.....	12
1.2. Le chômage	12
1.3. Le taux d'intérêt	12
1.4. Le taux d'inflation.....	12
1.5. Le taux de change.....	13
1.6. La concentration bancaire	13

2.	Facteurs internes du risque de crédit	13
2.1.	Taille de la banque.....	13
2.2.	La croissance du crédit.....	14
2.3.	La rentabilité des actifs et des capitaux propres.....	14
2.4.	Les provisions pour pertes.....	14
2.5.	Le ratio dépôts sur crédit.....	15
Section 3 : La réglementation du risque de crédit.....		16
1.	La réglementation internationale du risque de crédit.....	16
1.1	La réglementation Bâle I.....	16
1.2	La réglementation Bâle II.....	18
1.2.1	Pilier I : exigences minimales en fonds propres	18
1.2.2	Le pilier II : processus de surveillance prudentielle	19
1.2.3	Le pilier III : discipline de marché	19
1.3	La réglementation Bâle III	20
2.	La réglementation prudentielle en Tunisie.....	21
2.1	Division des risques	21
2.2	Couverture des risques.....	22
2.3	Classification des actifs.....	22
Conclusion		24
CHAPITRE 2 : LE STRESS TEST ET GESTION DES RISQUES		25
Introduction.....		26
Section 1 : Introduction aux stress tests		27
1.	L'évolution des stress tests.....	27
2.	Définition de stress test	28
3.	Les objectifs des stress tests bancaires	29
3.1.	Structure de gouvernance et stress tests	29
3.2.	Gestion des risques et stress tests.....	30
4.	Value at Risk et stress test	30
Section 2 : Classification, méthodologies et modèles de stress tests.....		32
1.	Les types des stress tests.....	32
1.1.	Test de sensibilité	32
1.2.	Tests de scénarios	32
1.2.1.	Les types de scénarios stress tests	32
1.2.2.	La conception des scénarios stress tests.....	33
1.3.	Approche du stress test inversé.....	33
2.	Les approches de stress test.....	34
3.	Les modèles de stress test.....	35
3.1.	Les modèles Micro prudentiel	35

3.2. Les modèles Macro prudentiel.....	35
Section 3 : Mise en place des stress tests : procédures et démarches	38
1. Les étapes clés de la mise en place des stress tests.....	38
2. Mise en œuvre des stress tests de crédit	38
3. Etudes empiriques des stress tests sur le risque de crédit	39
4. Avantage de l'application de stress tests avec la modélisation BSVAR.....	41
Conclusion	43
CHAPITRE 3 : APPLICATION DU STRESS TEST DE RISQUE DE CREDIT	44
Introduction	45
Section 1 : Présentation et organisation de la BFPME	46
1. Présentation et historique de la BFPME	46
1.1. Historique de la BFPME	46
1.2. La stratégie de la BFPME	46
2. Présentation de la direction des risques	47
Section 2 : Modélisation du risque de crédit.....	48
1. Méthodologie de recherche.....	48
1.1. Présentation du modèle VECM	48
1.2. Présentation du modèle BSVAR.....	48
1.3. Présentation des données.....	49
2. Estimation des modèles	50
2.1. Application du modèle VECM.....	51
2.1.1. Les tests des pré-estimations.....	51
2.1.2. Estimation du modèle VECM	53
2.2. Application de l'approche BSVAR.....	53
2.2.1. Spécification des contraintes d'identification.....	55
2.2.2. Détermination de la distribution à priori.....	57
2.2.3. Estimation du modèle BSVAR.....	60
2.3. Comparaison des performances entre les modèles VECM et BSVAR.....	61
2.3.1. Critère de l'Erreur Quadratique Moyenne de Prévision.....	61
2.3.2. Test de Diebold-Mariano	63
2.3.3. Test de la dominance de prévision.....	64
2.4. Analyse des chocs structurels et décomposition de la variance	65
Section 3 : Application du stress test sur le risque de crédit	67
1. La création des scénarios de stress	67
2. Les résultats des scénarios d'intuition	69
3. Recommandation	72
3.1. Recommandation statistique.....	72
3.2. Recommandation sur la réflexion des décideurs.....	73

3.3. Recommandation stratégique de la BFPME.....	74
Conclusion	75
CONCLUSION GENERALE	76
BIBLIOGRAPHIE.....	78
ANNEXES.....	83
TABLE DES MATIERES	112

RESUME

L'objectif de notre travail est d'appliquer le stress test inversé sur le risque de crédit afin d'évaluer l'impact des décisions prises par les responsables sur le niveau des prêts non performants. Pour ce faire, nous avons suivi une approche en deux étapes : tout d'abord, une approche descriptive pour présenter les bases théoriques du risque de crédit et du stress test, puis une approche empirique. Dans cette approche empirique, nous avons critiqué le modèle VECM et construit un modèle BSVAR de risque de crédit plus complet. Enfin, nous avons adopté une démarche analytique pour évaluer la capacité de la banque après l'application des scénarios construits.

Les résultats de notre étude empirique indiquent une précision significative du modèle BSVAR par rapport au modèle VECM en termes de prévisions. Cela démontre l'importance de l'intégration de la matrice des effets instantanés et de la distribution à priori, qui enrichit le modèle en termes d'informations. La conception de la distribution à priori nous a conduit à la construction des scénarios qui décrivent la réaction des décideurs de la BFPME face à l'arrivée de nouvelles informations. L'analyse des résultats du stress test inversé dans le cas du choc extrême nous indique que vers la fin de l'année 2025, tous les prêts accordés seront non performants. Cependant, sur la base de l'analyse des niveaux des hyperparamètres, nous avons pu décrire cette intuition et formuler des recommandations.

Les mots clés : stress test inversé, modèle VECM, modèle BSVAR, distribution à priori, Statistique bayésienne, Matrice d'identification, scénarios.

ABSTRACT

The objective of our work is to apply the reverse stress test on credit risk to evaluate the impact of decisions made by the managers on the level of non-performing loans. To achieve this, we followed a two-step approach: firstly, a descriptive approach to present the theoretical foundations of credit risk and stress testing, and then an empirical approach. In this empirical approach, we criticized the VECM model and built a more comprehensive BSVAR model of credit risk. Finally, we adopted an analytical approach to assess the bank's capacity after the application of the constructed scenarios.

The results of our empirical study indicate a significant accuracy of the BSVAR model compared to the VECM model in terms of forecasts. This demonstrates the importance of integrating the matrix of instantaneous effects and à priori distribution, which enriches the model in terms of information. The design of the à priori distribution led us to construct scenarios that describe the reaction of BFPME decision-makers to the arrival of new information. The analysis of the results of the reverse stress test in the case of an extreme shock indicates that by the end of 2025, all granted loans will be non-performing. However, based on the analysis of hyperparameter levels, we were able to describe this intuition and formulate recommendations.

Keywords : reverse stress test, VECM model, BSVAR model, à priori distribution, Bayesian statistics, identification matrix, scenarios.