



THESIS / THÈSE

MASTER EN INGÉNIEUR DE GESTION À FINALITÉ SPÉCIALISÉE EN DATA SCIENCE

Quel est l'impact des agents chartistes machine learner sur la stabilité des marchés de change ? - Simulations via un modèle à agents hétérogènes

Sluyters, Victor

Award date:
2022

Awarding institution:
Universite de Namur

[Link to publication](#)

General rights

Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal ?

Take down policy

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.



**UNIVERSITÉ
DE NAMUR**

Quel est l'impact des agents chartistes machine learner sur la stabilité des marchés de change ?

Simulations via un modèle à agents hétérogènes

Victor **SLUYTERS**

Directrice de Mémoire : **Prof. Sophie Béreau**

*Mémoire présenté en vue de l'obtention du titre de Master 120 en Ingénieur de
Gestion, à finalité spécialisée en Data Science*

Année académique 2021-2022

Université de Namur, ASBL

Faculté des Sciences économiques, sociales et de gestion - Département des Sciences de gestion

Rempart de la Vierge 8, B-5000 Namur, Belgique, Tel. +32 [0]81 72 49 58/48 41

Résumé/Summary

Résumé

Dans ce mémoire, nous nous intéressons à l'impact des agents chartistes machine learner sur la stabilité des marchés de change. Nous étudions cet impact en comparant les dynamiques générées par trois modèles à agents hétérogènes : un modèle « à la De Grauwe et Grimaldi » et deux extensions de ce modèle. Dans notre première extension, nous remplaçons l'heuristique chartiste du modèle de référence par une heuristique chartiste plus sophistiquée reposant sur des méthodes d'apprentissage automatique. Dans notre seconde extension, la nouvelle heuristique chartiste ne remplace pas l'ancienne heuristique, mais est ajoutée à l'ensemble des règles de prédiction pouvant être employées par les agents du modèle. Nos résultats indiquent que la présence d'agents chartistes machine learner permet en moyenne de stabiliser les marchés de change. Néanmoins, cette influence positive est réduite lorsque les agents machine learner cohabitent avec des agents chartistes n'employant pas de méthode d'apprentissage automatique.

Summary

In this master thesis, we investigate the impact of chartist agents using machine learning on the stability of foreign exchange markets. We evaluate this impact by comparing the dynamics generated by three heterogeneous agent models : a model « à la De Grauwe and Grimaldi » and two extensions of this model. In our first extension, we replace the chartist heuristic of the reference model by a more sophisticated chartist heuristic based on machine learning tools. In our second extension, the new chartist heuristic does not substitute the former heuristic but is added to the set of prediction rules that can be used by the agents of the model. Our results indicate that the presence of chartist machine learner agents stabilizes foreign exchange markets on average. However, this positive influence is reduced when machine learner agents coexist with chartist agents that do not use machine learning methods.

Remerciements

Je souhaite en premier lieu remercier chaleureusement ma promotrice, le Professeur Béreau, pour ses conseils, son implication et son accompagnement tout au long de ce mémoire.

Dans un deuxième temps, je souhaite montrer mon entière reconnaissance à l'ensemble du corps professoral de la Faculté des Sciences économiques, sociales et de gestion de l'Université de Namur pour la qualité de l'enseignement qui m'a été prodigué durant ces cinq dernières années.

Enfin, j'adresse ma profonde gratitude à ma famille et mes amis pour leur soutien incommensurable durant mes études et la rédaction de ce mémoire.

Table des matières

1. Introduction	1
2. Revue de littérature	4
2.1. Modèles à agents hétérogènes	4
2.1.1. Finance néo-classique et émergence de la finance comportementale	4
2.1.2. Modèles multi-agents	5
2.1.3. Modèles à agents hétérogènes	6
2.2. Machine learning et finance	7
3. Méthodologie	11
3.1. Présentation du modèle de référence	11
3.2. Extensions du modèle de référence	16
3.2.1. Remplacement des agents chartistes	18
3.2.2. Ajout des agents chartistes machine learner	20
3.3. Méthodologie employée pour l'analyse des résultats	21
3.3.1. Pertinence des modèles	23
3.3.2. Impact des agents machine learner sur la stabilité des marchés	25
4. Analyse des résultats	27
4.1. Remplacement des agents chartistes	27
4.1.1. Pertinence du modèle	27
4.1.2. Impact des agents machine learner sur la stabilité des marchés	30
4.1.3. Analyse de sensibilité	37
4.2. Ajout des agents chartistes machine learner	42
4.2.1. Pertinence du modèle	42
4.2.2. Impact des agents machine learner sur la stabilité des marchés	45
4.2.3. Analyse de sensibilité	51
4.3. Comparaison des deux extensions	54
5. Discussion	57
5.1. Résumé des résultats	57
5.2. Parallèles avec la littérature	58
5.3. Limites et pistes d'amélioration	58
6. Conclusion	61

7. Bibliographie	63
8. Annexes	68
8.1. Codes	68
8.1.1. Code - Modèle de référence	68
8.1.2. Code - Remplacement des agents chartistes	72
8.1.3. Code - Ajout des agents chartistes machine learner	77
8.2. Remplacement des agents chartistes - Analyse de sensibilité	84
8.2.1. Degré d'extrapolation des agents chartistes	84
8.2.2. Sensibilité des agents à la profitabilité des heuristiques	88
8.2.3. Nombre de retards considérés par les agents machine learner	92
8.2.4. Algorithme utilisé par les agents machine learner	96
8.3. Ajout des agents chartistes - Analyse de sensibilité	104
8.3.1. Degré d'extrapolation des agents chartistes	104
8.3.2. Sensibilité des agents à la profitabilité des heuristiques	108
8.3.3. Nombre de retards considérés par les agents machine learner	112
8.3.4. Algorithme utilisé par les agents machine learner	116
8.4. Comparaison des deux extensions	124

1. Introduction

En quelques décennies, la nature des marchés financiers a profondément changé. À l'origine composés uniquement d'agents humains, les marchés sont aujourd'hui des espaces hybrides dans lesquels humains et machines interagissent et échangent des actifs. La popularisation et l'adoption massive de méthodes d'apprentissage automatique (ou « machine learning » en anglais, une branche de l'intelligence artificielle) illustrent parfaitement l'importance croissante des machines sur les marchés financiers. Cette progression a été favorisée par de nombreux facteurs tels que l'accès à de grandes quantités de données à moindres coûts, l'avènement du big data, l'accroissement de la puissance de calcul des ordinateurs et la création de bibliothèques open source (e.g., scikit-learn et TensorFlow) permettant d'implémenter facilement des méthodes d'apprentissage automatique, etc. Présentes sous plusieurs formes, de simples outils d'aide à la décision à entités capables d'accomplir des tâches sans intervention humaine, ces machines permettent le plus souvent aux traders d'améliorer leurs performances, mais à quel prix ? Quel est leur impact sur la stabilité des marchés ? Peuvent-elles être à l'origine de crises financières ou permettent-elles, au contraire, d'améliorer l'efficacité des marchés ? Alors que la crise du COVID-19 a accéléré la digitalisation de notre économie et, ce faisant, a accentué la progression de l'intelligence artificielle sur les marchés financiers, il devient crucial de répondre à ces questions.

Dans ce mémoire, nous apportons des éléments de réponse à ces questions en nous focalisant sur la question de recherche suivante : **quel est l'impact des agents chartistes machine learner sur la stabilité des marchés de change ?** Nous raisonnons sur base de données simulées via des modèles à agents hétérogènes afin de pouvoir identifier les agents machine learner et isoler leur impact sur la stabilité. L'intérêt de cette recherche est double. D'une part, nos résultats pourraient contribuer aux discussions concernant les nouvelles réglementations et lignes directrices à adopter sur les marchés financiers. D'autre part, ce mémoire pourrait mener à une modélisation plus réaliste d'un marché de change (FOREX). Les techniques de machine learning sont, en effet, de plus en plus utilisées par les traders (OECD, 2021) et devraient donc être intégrées dans les modèles cherchant à simuler les marchés financiers.

Comme indiqué précédemment, nous nous intéressons à l'influence des agents chartistes machine learner sur la stabilité des marchés de change. Nous mesurons l'impact de ces agents en comparant les dynamiques générées par trois modèles à agents hétérogènes : un modèle de référence « à la De Grauwe et Grimaldi » et deux extensions de ce modèle.

Contrairement aux modèles basés sur les hypothèses d'homogénéité et de rationalité parfaite des agents, les modèles à agents hétérogènes permettent d'expliquer et de répliquer de nombreux faits empiriques observés sur les marchés financiers (Zhao and Li, 2022). Ces modèles considèrent les

marchés comme des systèmes complexes dans lesquels des agents faisant preuve d'une rationalité limitée et possédant des croyances hétérogènes interagissent. Les dynamiques simulées par ce type de modèles émergent des interactions et des croyances de leurs agents.

Les croyances des agents de nos modèles sont définies par un ensemble limité d'heuristiques. Au début de chaque période, les agents prédisent l'évolution du taux de change sur base d'une de ces heuristiques. L'évolution réelle du taux de change dépend des attentes des agents et d'un bruit blanc gaussien. Ce dernier correspond aux nouvelles informations n'ayant pas été incorporées dans les prédictions des agents. Après chaque période, les agents évaluent la performance de l'heuristique qu'ils ont sélectionnée à la période précédente et révisent au besoin leur stratégie. Les agents de notre modèle de référence ont accès à deux heuristiques. La première est une règle de prédiction chartiste relativement simple. En adoptant cette heuristique, les agents tentent de prédire l'évolution du taux de change à partir de ses valeurs passées. La seconde est une règle fondamentaliste. En préférant cette heuristique, les agents cherchent à anticiper l'évolution du taux de change en se basant sur sa valeur fondamentale.

Dans notre première extension, nous remplaçons l'heuristique chartiste du modèle de référence par une règle de prédiction chartiste plus complexe estimée à l'aide de LASSO (Least Shrinkage and Selection Operator), un outil d'apprentissage automatique particulièrement adapté aux hypothèses des modèles à agents hétérogènes. Le remplacement de l'heuristique chartiste nous permet d'isoler et d'évaluer l'impact d'agents chartistes machine learner sur la stabilité des marchés de change. Dans notre seconde extension, la nouvelle règle de prédiction chartiste ne remplace pas l'ancienne, mais est ajoutée à l'ensemble des heuristiques pouvant être employées par les agents du modèle. Grâce à cette deuxième extension, nous pouvons estimer l'influence des agents machine learner sur la stabilité des marchés lorsque ceux-ci cohabitent avec des agents chartistes n'adoptant pas de méthode d'apprentissage automatique.

Les résultats de nos deux extensions indiquent que la présence d'agents chartistes machine learner sur les marchés de change permet en moyenne de stabiliser ces derniers. L'utilisation de techniques d'apprentissage automatique par certains agents permet notamment de réduire la variance du taux de change, la distance moyenne entre le taux de change et sa valeur fondamentale, le nombre de bulles et de krachs. Cependant, la présence d'agents machine learner semble prolonger la durée des périodes d'instabilité. De plus, l'effet stabilisateur des agents machine learner est atténué lorsque ces derniers cohabitent avec des agents chartistes n'employant pas de méthode d'apprentissage automatique.

Nos conclusions sont notamment cohérentes avec les résultats de Georges and Pereira (2021), deux chercheurs ayant également employé un modèle à agents hétérogènes afin de mesurer l'influence

des agents machine learner sur la stabilité des marchés¹. De plus, nos conclusions corroborent les résultats de plusieurs études s'intéressant à l'impact du trading algorithmique sur la qualité et l'efficacité des marchés².

La suite de ce mémoire est organisée de la façon suivante : premièrement, nous procédons à une brève revue de littérature afin d'introduire les modèles à agents hétérogènes, l'utilisation de méthodes d'apprentissage automatique sur les marchés et les questions que soulève cette dernière. Dans un deuxième temps, nous présentons la méthodologie employée afin de répondre à notre question de recherche. Troisièmement, nous détaillons les résultats obtenus pour nos deux extensions. Nous comparons, ensuite, ces résultats à la littérature existante, évoquons les limites de ce mémoire et suggérons de futurs développements. Enfin, nous concluons ce travail en résumant brièvement son contenu.

1. Néanmoins, leur modèle était uniquement composé d'agents chartistes.

2. Nous comparons nos résultats à ceux de ces études, car les agents machine learner de nos extensions peuvent être considérés comme des traders algorithmiques.

2. Revue de littérature

Dans cette section, nous illustrons l'intérêt de notre recherche en expliquant le fonctionnement, le but et les accomplissements des modèles à agents hétérogènes et en démontrant l'importance croissante de l'apprentissage automatique sur les marchés financiers.

2.1. Modèles à agents hétérogènes

Les modèles à agents hétérogènes sont un type particulier de modèles multi-agents. En ne supposant pas l'homogénéité des agents et leur rationalité parfaite, les modèles multi-agents contribuent à la littérature comportementale. Ces concepts pouvant être nouveaux pour le lecteur, nous fournissons, ci-dessous, les explications nécessaires à la compréhension de ce travail.

2.1.1. Finance néo-classique et émergence de la finance comportementale

La finance néo-classique est le paradigme ayant dominé la littérature financière au cours des dernières décennies. Ce paradigme repose sur l'hypothèse d'efficience des marchés. Bien que possédant différentes formes, cette hypothèse peut être synthétisée de la manière suivante : le prix des actifs reflète toute l'information disponible. En conséquence, le prix d'un actif correspond à sa valeur fondamentale. L'hypothèse d'efficience des marchés est intimement liée à la notion d' « homo economicus ». De nombreuses théories économiques et financières font l'hypothèse que les agents sont des « homo economicus » (Singh, Babshetti, and Shivaprasad, 2021). Ce concept fut introduit par Mill (1874). Un « homo economicus » est un agent cherchant à maximiser sa richesse et privilégiant son intérêt personnel. Il est parfaitement rationnel et dispose d'une information parfaite.

Considérer que les agents économiques sont des « homo economicus » est une hypothèse très forte et irréaliste. Au cours des dernières décennies, une multitude d'auteurs ont rejeté cette hypothèse et ses composantes. Parmi celles-ci, l'hypothèse de rationalité parfaite des agents a particulièrement été au centre des critiques. Cela a mené au développement de l'hypothèse de rationalité limitée (e.g., Sargent, 1993 ; Shefrin, 2008 ; Simon, 1957). Contrairement à l'hypothèse de rationalité parfaite, l'hypothèse de rationalité limitée suppose que les agents sont incapables de connaître parfaitement leur environnement, qu'ils possèdent une capacité de calcul limitée et qu'ils subissent des coûts pour obtenir et traiter des informations. À cause de ces difficultés, les agents ne peuvent pas adopter des règles de décision parfaitement optimales dans les situations incluant de l'incertitude. Ainsi, les agents prennent leurs décisions en utilisant des heuristiques. Une heuristique est une règle relativement simple, rapide et fonctionnant généralement bien. En fonction de l'information disponible, les agents sélectionnent l'heuristique pour laquelle ils s'attendent à la meilleure performance. Étant conscients que l'heuristique utilisée ne délivre potentiellement pas le meilleur résultat, les agents

évaluent leur heuristique lorsque de nouvelles informations sont disponibles. Selon leur conclusion, ils révisent ou non leur choix d'heuristique. L'utilisation d'heuristiques lors de décisions sous incertitude a été démontrée par Tversky and Kahneman (1974).

La finance néo-classique est à l'origine de nombreuses avancées et contributions. Néanmoins, elle ne permet pas d'expliquer certains phénomènes fréquemment observés sur les marchés tels que les clusters de volatilité, l'excès de volatilité, les queues épaisses de distribution des rendements (Zhao and Li, 2022). La finance néo-classique est ainsi rejetée par de nombreuses études empiriques (Dieci and He, 2018). De plus, comme introduit précédemment, elle repose sur des hypothèses fortes dont certaines sont peu plausibles. Ces limites ont provoqué l'émergence d'un nouveau paradigme : la finance comportementale (Dieci and He, 2018).

La finance comportementale s'intéresse à l'influence de la psychologie sur le comportement et les décisions des agents ainsi qu'à ses conséquences sur les marchés (Kapoor and Prosad, 2017).

À l'inverse de la finance néo-classique, la finance comportementale ne suppose pas que les agents présents sur les marchés financiers sont parfaitement rationnels (Barberis and Thaler, 2002). Ce faisant, elle ne fait pas l'hypothèse que les marchés financiers sont toujours efficaces (i.e., le prix d'un actif ne reflète pas toujours toute l'information disponible et ne correspond donc pas toujours à sa valeur fondamentale). En effet, les prix des actifs peuvent dévier de leurs valeurs fondamentales, car les agents sont limités dans leur rationalité. Ceux-ci utilisent des heuristiques et sont sujets à différents biais. En conséquence, les agents font des erreurs et prennent des décisions sous-optimales (Kapoor and Prosad, 2017). L'accumulation d'erreurs et de décisions sous-optimales par les agents peut mener aux « anomalies³ » observées sur les marchés.

Les modèles multi-agents (et, par conséquent, les modèles à agents hétérogènes) supposent que les agents font preuve d'une rationalité limitée et qu'ils ne possèdent pas tous les mêmes attentes. Ce faisant, ces modèles contribuent à la littérature comportementale.

2.1.2. Modèles multi-agents

Les modèles multi-agents modélisent un système comme un grand nombre d'entités prenant des décisions de manière autonome (Bonabeau, 2002). Ces entités sont généralement appelées des agents. Le comportement de chaque agent est basé sur un ensemble de règles et sur la situation dans laquelle l'agent se trouve. Les agents prennent des décisions à un niveau individuel, interagissent entre eux et apprennent sur base de leurs expériences. Ces choix et interactions sont à l'origine des dynamiques agrégées du système.

3. Les phénomènes ne pouvant être expliqués par l'hypothèse d'efficience des marchés sont nommés anomalies par certains chercheurs.

Incorporer de l'hétérogénéité dans les comportements des agents permet aux modèles multi-agents de générer des dynamiques de prix similaires à celles observées sur les marchés (Raman and Leidner, 2019). Les dynamiques simulées par ces modèles émergent des comportements et des interactions des agents (Manzan, 2009). Ainsi, ce type de modèle est capable de générer des périodes de stress et de stabilité et de reproduire de nombreux faits stylisés⁴ sans avoir été spécifiquement programmé pour le faire (Lux and Zwickels, 2018).

Néanmoins, ne pas supposer l'homogénéité et la rationalité parfaite des agents signifie que de nouvelles hypothèses concernant le comportement des agents doivent être formulées. Cela introduit énormément de liberté au niveau de la modélisation. Il est important que ces nouvelles hypothèses soient réalistes. Idéalement, elles doivent être validées par des enquêtes, des expériences en laboratoire ou des études empiriques (Lux and Zwickels, 2018).

Les modèles multi-agents possèdent énormément de paramètres. Faire varier leurs valeurs permet de générer de nombreuses données et situations différentes. Cela rend les modèles multi-agents très intéressants pour entraîner des algorithmes, estimer l'impact d'une nouvelle loi ou régulation, évaluer la performance de stratégies de trading, etc (Raman and Leidner, 2019). Illustrons l'avantage d'utiliser des données simulées à l'aide de deux exemples. Considérons pour notre premier exemple l'entraînement d'un algorithme de trading. En ne considérant que des données historiques, nous sommes limité au niveau de la quantité de données disponibles et nous ne considérons que des situations s'étant déjà produites. Incorporer des données réalistes mais simulées permet d'entraîner le modèle et de tester sa performance sur de nouvelles données. Cela augmente la robustesse de notre modèle face à des données qu'il n'a jamais rencontrées. Pour notre deuxième exemple, nous nous focalisons sur l'introduction d'une nouvelle régulation. Les données historiques ne permettent pas d'isoler l'impact d'une nouvelle loi (Mizuta, 2016). Il est possible de le faire avec un modèle multi-agents. De plus, il est facile de tester différentes variations de la loi et de générer des situations d'instabilité sur le marché afin d'étudier les conséquences de l'introduction de la nouvelle loi dans des situations de stress.

2.1.3. Modèles à agents hétérogènes

Comme indiqué au début de la sous-section 2.1, les modèles à agents hétérogènes sont un type spécifique de modèles multi-agents. Plus spécifiquement, ces modèles sont moins complexes, car ils comportent moins de variables, moins d'heuristiques et des mécanismes d'interaction plus simples. Par conséquent, leurs propriétés et les mécanismes à l'origine des dynamiques observées sur les marchés simulés peuvent être plus facilement analysés (Dieci and He, 2018).

4. Les faits stylisés sont des régularités empiriques observées sur les marchés financiers. Celles-ci sont stables dans le temps et présentes sur les différents marchés financiers.

Un modèle à agents hétérogènes représente un marché financier comme étant un système complexe composé par un ensemble d'agents. Les agents sont hétérogènes, font preuve d'une rationalité limitée et cherchent généralement à anticiper l'évolution du prix d'un actif financier. Étant incapables de comprendre la complexité de l'environnement dans lequel ils opèrent, les agents prennent leurs décisions en sélectionnant une heuristique parmi un ensemble restreint (généralement deux à trois heuristiques). Les agents sont rationnels et sont donc conscients que l'utilisation d'une heuristique produit généralement une solution sous-optimale. Ainsi, ils évaluent régulièrement leur choix d'heuristique et adaptent leur comportement sur base des performances récentes des différentes règles de prédiction. L'évolution des proportions d'agents par heuristique détermine les dynamiques des séries financières simulées. Ces dynamiques influencent à leur tour l'évolution des proportions d'agents par heuristique (Akçay and Hirshleifer, 2021). En amplifiant les chocs et en provoquant d'importantes fluctuations au niveau de la série simulée, ce mécanisme de rétroaction est responsable de la non-linéarité des modèles à agents hétérogènes (Zhao and Li, 2022).

Cette non-linéarité leur permet d'expliquer et de générer de nombreux faits stylisés ainsi que diverses anomalies (Zhao and Li, 2022). Par exemple, la capacité de ces modèles à reproduire les clusters de volatilité (Gauersdorfer and Hommes, 2007), le « power law behaviour » (He and Li, 2007 ; Lux and Alfarano, 2016), les queues de distribution épaisses des rendements (Kaizoji, 2003) et la présence d'autocorrélation dans les rendements (He and Li, 2008) a notamment été démontrée au cours des dernières décennies de recherche.

Pour plus d'informations sur les modèles à agents hétérogènes et les différentes études les impliquant, nous invitons le lecteur à consulter les excellentes revues de littérature proposées par Hommes (2006) et Dieci and He (2018).

2.2. Machine learning et finance

Avec l'accroissement rapide du volume de données disponibles et l'accès à une puissance de calcul toujours plus importante à moindres coûts, l'emploi de techniques d'intelligence artificielle est de plus en plus répandu en finance (OECD, 2021). Parmi ces techniques, nous retrouvons les méthodes d'apprentissage automatique. Celles-ci permettent aux agents d'améliorer leurs performances et leur capacité de prédiction en apprenant de manière automatique à partir de données.

L'apprentissage automatique est une branche de l'intelligence artificielle permettant aux machines d'apprendre et de s'adapter en découvrant des tendances dans les données via l'utilisation d'algorithmes et de modèles statistiques. On distingue trois principaux types d'apprentissage automatique : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. Dans un problème d'apprentissage supervisé, l'apprentissage est basé sur des exemples d'entrées et

de sorties de la fonction que le modèle cherche à apprendre. L'apprentissage supervisé est particulièrement adapté aux problèmes de classification et de régression. Dans les problèmes d'apprentissage non supervisé, les sorties de la fonction à apprendre ne sont pas données. L'identification de motifs récurrents dans les données est donc réalisée sans aucun indice. Avec l'apprentissage par renforcement, le système cherche à atteindre un objectif spécifique. Le système est récompensé lorsqu'il atteint cet objectif et est pénalisé lorsqu'il n'y parvient pas. La machine apprend par essai-erreur et cherche à maximiser les récompenses reçues.

Les techniques d'apprentissage supervisé sont les méthodes d'apprentissage automatique les plus répandues pour la prédiction du prix d'actions (Mailagaha Kumbure et al., 2022). Parmi celles-ci, les réseaux de neurones artificiels et les SVMs (« Support Vector Machines ») montrent les meilleures performances dans la littérature (Mailagaha Kumbure et al., 2022). Cependant, on observe depuis quelques années un nombre croissant d'études utilisant des méthodes de sélection et d'extraction de variables. Ces méthodes permettent d'obtenir des résultats plus simples à interpréter tout en améliorant potentiellement la performance. Selon Mailagaha Kumbure et al., la popularité des méthodes de sélection et d'extraction de variables devrait continuer à s'accroître au cours des prochaines années. LASSO faisant partie de ces méthodes, nous considérons que choisir LASSO pour nos agents machine learner est un choix judicieux.

La capacité des techniques d'apprentissage automatique à surpasser les méthodes traditionnellement utilisées pour des problèmes de prédiction a été démontrée de nombreuses fois dans la littérature (Consoli, Reforgiato Recupero, and Saisana, 2021 ; Gu, Kelly, and Xiu, 2020 ; Ryll and Seidens, 2019). Les méthodes d'apprentissage automatique sont en mesure de gérer des interactions non-linéaires et des données possédant un nombre considérable de dimensions. Elles sont également à même de détecter les valeurs/données aberrantes (« outliers »). Ces propriétés sont à l'origine de l'excellente capacité de prédiction des méthodes d'apprentissage automatique (Chen and Hao, 2017). Elles les rendent attrayantes pour prédire l'évolution des marchés financiers.

Ainsi, alors que les marchés financiers étaient à l'origine composés uniquement d'agents humains, ils sont aujourd'hui des espaces hybrides dans lesquels opèrent machines et humains (Georges and Pereira, 2021). L'utilisation de machines sur les marchés peut aller d'une simple aide à la décision (prédictions des prix, détermination du timing d'achat ou de vente, etc.) à du trading algorithmique⁵ (Kirilenko and Lo, 2013). La présence et l'importance de machines sur les marchés financiers sont d'ailleurs mises en avant par différentes études. Par exemple, Kaya and Schilbach (2016) ont montré que le trading à haute fréquence (« high frequency trading »), une forme de trading algorithmique, était responsable de pratiquement 50 % du volume d'actions échangées sur les

5. Nous parlons de trading algorithmique (aussi appelé trading automatisé) lorsque le processus de trading est géré par un ordinateur, sans la moindre intervention humaine.

marchés américains. Après avoir réalisé une enquête impliquant diverses FinTechs et institutions financières dans le monde, Ryll et al. (2020) ont indiqué que 60 % des gestionnaires de portefeuille interrogés avaient déjà eu recours à des techniques d'intelligence artificielle dans le cadre de leurs activités. L'importance de l'intelligence artificielle sur les marchés devrait encore augmenter. En effet, les acteurs financiers (banques, FinTechs, fonds d'investissement...) investissent de manière considérable afin d'acquérir des données et de maîtriser les méthodes d'apprentissage automatique (Goodell et al., 2021). De plus, le trading algorithmique semble de plus en plus présent sur les marchés (Chaboud et al., 2014).

L'importance croissante de l'intelligence artificielle sur les marchés financiers est une source d'inquiétudes pour les législateurs. D'une part, Chaboud et al. (2014) ont montré qu'il y avait moins de diversité dans les stratégies employées par les traders algorithmiques (machines) que dans les stratégies utilisées par les traders non-algorithmiques (humains). Cela étant, la convergence des stratégies basées sur des techniques d'apprentissage automatique pourrait mener à un nombre important d'achats (ou de ventes) à un même moment. Ainsi, le recours à des méthodes d'apprentissage automatique par un nombre important d'agents sur les marchés financiers pourrait déstabiliser les marchés en favorisant les comportements grégaires (« herding behaviour » en anglais) et en poussant les marchés à la hausse ou à la baisse de manière continue (OECD, 2021). Cela pourrait également mener à une augmentation de la volatilité du marché en provoquant d'importantes variations au niveau des prix des actifs. D'autre part, les techniques d'apprentissage automatique sont souvent considérées comme opaques. En effet, il est généralement difficile d'expliquer précisément les raisons pour lesquelles un modèle fait telle prédiction sur base de telles informations. En somme, malgré une (très) bonne capacité de prédiction, il est généralement difficile d'expliquer les résultats d'un modèle de machine learning (Burrell, 2016). À cause de cette opacité, les comportements et l'impact des stratégies impliquant de l'apprentissage automatique peuvent difficilement être compris et anticipés.

La popularité grandissante des méthodes d'apprentissage automatique sur les marchés pourrait donc générer de nouveaux risques ou intensifier ceux existants (OECD, 2021). Il est important que les législateurs développent de nouvelles lois et adaptent les régulations existantes afin de limiter les potentiels effets néfastes des techniques d'intelligence artificielle. Néanmoins, ces techniques sont à l'origine d'avantages compétitifs et permettent aux firmes financières d'améliorer leur rentabilité via une réduction des coûts et une amélioration de la productivité (OECD, 2021). Ces avantages peuvent également bénéficier aux clients en améliorant la qualité du service/produit fourni et/ou en réduisant son coût. Les législateurs doivent donc favoriser l'innovation, tout en minimisant les risques introduits par celle-ci. Pour ce faire, ils doivent être capables de comprendre l'impact de l'intelligence artificielle sur les marchés. Les modèles à agents hétérogènes que nous proposons

permettent d'isoler et de mesurer l'impact d'agents chartistes machine learner sur la stabilité des marchés. En ce sens, nous considérons que si les résultats de notre recherche sont probants, ils pourraient être particulièrement pertinents pour les législateurs.

3. Méthodologie

Dans cette section, nous détaillons la méthodologie utilisée afin d'évaluer l'impact des agents chartistes machine learner sur la stabilité des marchés de change. En pratique, trois modèles à agents hétérogènes ont été exploités au cours de cette étude :

1. un modèle « à la De Grauwe et Grimaldi » (modèle de référence) ;
2. une première extension de ce modèle, dans laquelle les agents chartistes du modèle de référence sont remplacés par des agents machine learner ;
3. une seconde extension du modèle de référence, dans laquelle des agents machine learner sont introduits sans remplacer les agents chartistes initialement présents.

L'impact résultant du remplacement ou de l'ajout d'un type d'agents dans le modèle de référence est étudié en comparant les simulations réalisées grâce au modèle de référence et à l'extension correspondante. Lors de l'analyse des résultats, notre attention est focalisée sur la capacité des modèles à reproduire certains faits stylisés et sur l'impact du remplacement ou de l'introduction d'un type d'agents sur la stabilité des marchés (bulles et/ou krachs).

La suite de cette section est organisée de la façon suivante. Tout d'abord, notre modèle de référence (modèle « à la De Grauwe et Grimaldi ») est introduit. Ensuite, les deux extensions de ce modèle sont présentées. Enfin, les principales méthodes et techniques utilisées pour l'analyse des résultats sont abordées.

3.1. Présentation du modèle de référence

Dans cette sous-section, nous décrivons un modèle non-linéaire de taux de change « à la De Grauwe et Grimaldi ». Ce modèle à agents hétérogènes est en phase avec les principes et le cadre de finance comportementale présentés dans le chapitre 2 de « The Exchange Rate in a Behavioral Finance Framework » (De Grauwe and Grimaldi, 2018). De plus, il est très proche d'un modèle proposé par De Grauwe et Grimaldi et utilisé par ces derniers dans de nombreux articles, notamment (De Grauwe and Grimaldi, 2002, 2005a, 2005b, 2006 ; De Grauwe and Rovira Kaltwasser, 2006). Il a également déjà été utilisé afin d'étudier les conséquences de l'introduction de nouveaux types d'agents sur la stabilité des marchés simulés (notamment Béreau, 2013). En outre, ce modèle permet de reproduire plusieurs anomalies observées sur les marchés de taux de change, notamment les queues de distribution épaisses des rendements, l'excès de volatilité, les clusters de volatilité et la déconnexion du taux de change des variables fondamentales sous-jacentes. Pour toutes ces raisons, nous considérons que ce modèle est une référence pertinente pour répondre à notre question de recherche.

Dans ce modèle de référence, les croyances/attentes des agents opérant sur le marché dictent les dynamiques du taux de change. Ces croyances concernent l'évolution future du taux de change. Elles divergent selon les agents et peuvent varier au cours du temps. En pratique, au début de chaque période, les agents estiment l'évolution future du taux de change à l'aide d'une heuristique (une règle de prédiction très basique) sélectionnée parmi un ensemble restreint à disposition des agents. Après chaque période, les agents évaluent leur choix via un score de « fitness » (dans notre cas, en comparant le revenu ajusté au risque délivré par la règle sélectionnée aux revenus ajustés au risque des autres heuristiques). Si le score de « fitness » ne supporte plus l'emploi d'une heuristique, les agents se tournent vers une règle présentant un score plus important (i.e., une règle plus profitable). En ce sens, les agents du modèle font preuve d'une rationalité limitée. En effet, ils ne sont pas irrationnels puisqu'ils évaluent les règles de prédiction sur base de leurs performances passées. Cependant, ces heuristiques n'incorporent qu'une faible partie de l'information totale disponible. Les agents ne sont donc pas parfaitement rationnels. Nous faisons l'hypothèse qu'aucun agent n'entre ou ne sort du marché. Par conséquent, le nombre d'agents sur le marché est constant. Seule la proportion d'agents utilisant une heuristique spécifique varie au cours du temps. Dans cette configuration du modèle, les agents ne peuvent choisir qu'entre deux règles de prédiction : une règle chartiste et une règle fondamentaliste.

Bien qu'il puisse sembler simpliste, le fonctionnement général du modèle s'appuie sur une vaste littérature. D'une part, l'emploi d'heuristiques par les agents financiers est largement documenté. D'autre part, de nombreuses études supportent la dichotomie chartiste-fondamentaliste. En effet, différents auteurs ont démontré l'utilisation de méthodes d'analyse technique par les agents financiers. Par exemple, Kavajecz and Odders-White (2004) indiquent l'utilisation de telles méthodes par la plupart des banques d'investissement et sociétés de trading. Divers auteurs fournissent également des preuves concernant l'hétérogénéité des agents sur les marchés. Des résultats de sondages (Menkhoff, 2010; Menkhoff and Taylor, 2007) et des preuves expérimentales (Heemeijer, Hommes, Sonnemans, and Tuinstra, 2009; Hommes, Sonnemans, Tuinstra, and van de Velden, 2005) supportent aussi la dichotomie chartiste-fondamentaliste. Les marchés des changes ne font pas exception puisque différentes études empiriques (Allen and Taylor, 1990; Cheung, Chinn, and Marsh, 2004; Frankel and Froot, 1987, 1990; Menkhoff, 1998; Taylor and Allen, 1992) attestent de divergences en termes d'informations et/ou de croyances, de l'utilisation de méthodes d'analyse technique et d'analyse fondamentale sur ces marchés. Ces études montrent également que certains agents changent de stratégie au fil du temps afin d'en adopter une plus profitable.

Dans ce modèle, les agents utilisant la règle chartiste cherchent à déduire l'évolution future du taux de change sur base de ses changements passés. En ne tenant pas compte de la valeur fondamentale du taux de change, ces agents peuvent être qualifiés de « noise traders » (De Long et al., 1990).

Les « noise traders », dont la présence sur les marchés financiers a notamment été établie par Lee, Shleifer, and Thaler (1991), sont une grande source de volatilité (Ramiah, Xu, and Moosa, 2015). Les agents chartistes du modèle ont donc un caractère déstabilisant. Ces derniers fondent leurs attentes sur base de la variation du taux de change observée à la période t pour prédire la variation à la période $t+1$. En d'autres termes :

$$E_t^c [\Delta s_{t+1}] = \beta \cdot \Delta s_t \quad (1)$$

$$E_t^c [s_{t+1}] = s_t + \beta \cdot \Delta s_t \quad (2)$$

où β représente le paramètre d'extrapolation utilisé par les chartistes. Ce paramètre est strictement supérieur à 0. En conséquence, l'heuristique employée par les agents chartistes est une règle à feedback positif.

Les fondamentalistes, quant à eux, anticipent l'évolution du taux de change en comparant la valeur de marché du taux de change avec sa valeur fondamentale. Leurs anticipations sont données par :

$$E_t^f [\Delta s_{t+1}] = -\psi \cdot (s_t - s_t^*) \quad (3)$$

$$E_t^f [s_{t+1}] = s_t - \psi \cdot (s_t - s_t^*) \quad (4)$$

où s_t^* correspond à la valeur fondamentale du taux de change à la période t et le paramètre ψ représente le pourcentage de mauvais alignement (i.e., $s_t - s_t^*$) qu'ils s'attendent à voir corrigé lors de la prochaine période. Cette heuristique suppose que les agents connaissent la valeur fondamentale du taux de change avec certitude.

L'heuristique fondamentaliste est une règle à feedback négatif. En effet, lorsque le taux de change est supérieur à sa valeur fondamentale (surestimation du taux de change), les agents fondamentalistes prédisent une baisse du taux de change. Inversement, lorsque le taux de change est inférieur à sa valeur fondamentale, les fondamentalistes s'attendent à une hausse du taux de change. En « poussant » le taux de change vers sa valeur fondamentale, les agents fondamentalistes représentent une force stabilisatrice sur les marchés.

Dans ce modèle, nous supposons que la valeur fondamentale du taux de change suit une marche aléatoire sans dérive. Soit :

$$s_{t+1}^* = s_t^* + \varepsilon_t, \quad \varepsilon_t \sim i.i.d. \mathcal{N}(0, \sigma_\varepsilon^2) \quad (5)$$

Comme précisé précédemment, les agents évaluent la performance de leur règle de prédiction à l'aide d'un score de « fitness » après chaque période. Pour ce faire, ils comparent les profits ajustés

au risque réalisés grâce à cette règle avec les profits ajustés au risque délivrés par les différentes heuristiques. Sur base de cette comparaison, ils décident ensuite de poursuivre l'utilisation de la règle de prédiction qu'ils avaient précédemment sélectionnée ou d'en changer. Le modèle repose ainsi sur une logique de dynamiques évolutives (« evolutionary dynamics » en anglais) : les agents font un choix ex ante et évaluent ce choix une fois son résultat observable (ex post). Si la règle choisie n'a pas délivré un profit ajusté au risque suffisant, les agents révisent leurs décisions et s'orientent vers une règle plus profitable.

Cette logique est implémentée dans notre modèle grâce à l'utilisation d'un modèle à choix discrets, une approche proposée par Brock and Hommes (1997). Celle-ci décrit raisonnablement bien le comportement des agents (Anufriev, Bao, and Tuinstra, 2016; Dieci and He, 2018) et est utilisée dans de nombreux modèles à agents hétérogènes. Elle permet de déterminer la répartition des agents entre les différentes heuristiques sur base des profits passés relatifs à ces heuristiques. Bien que des retards (ou « lags ») puissent être facilement introduits dans l'approche de Brock and Hommes (1997), la plupart des modèles à agents hétérogènes utilisant cette dernière ne considèrent que les profits de la période précédente. Suivant cette logique, la proportion d'agents dans notre modèle utilisant une heuristique au temps t est basée sur les profits ajustés au risque de la période précédente :

$$w_{c,t} = \frac{\exp[\gamma \cdot \pi'_{c,t}]}{\exp[\gamma \cdot \pi'_{c,t}] + \exp[\gamma \cdot \pi'_{f,t}]} \quad (6)$$

$$w_{f,t} = \frac{\exp[\gamma \cdot \pi'_{f,t}]}{\exp[\gamma \cdot \pi'_{c,t}] + \exp[\gamma \cdot \pi'_{f,t}]} \quad (7)$$

où $\pi'_{c,t}, \pi'_{f,t}$ sont respectivement les profits ajustés au risque réalisés au temps t de la règle chartiste et de la règle fondamentaliste. Notons que $\pi'_{c,t} = \pi_{c,t} - \mu \sigma_{c,t}^2$, $\pi'_{f,t} = \pi_{f,t} - \mu \sigma_{f,t}^2$. Le paramètre γ mesure l'intensité avec laquelle les agents révisent leur règle de prédiction. Lorsque ce paramètre est élevé, les agents réagissent fortement aux profits relatifs des règles. Si γ était infini, tous les agents sélectionneraient la règle de prédiction la plus profitable. Quand γ est égal à 0, les agents sont insensibles aux profits relatifs des règles. Par conséquent, ils ne changent jamais de règle de prédiction. D'un point de vue comportemental, ce paramètre γ mesure le biais de statu quo présenté par Kahneman, Knetsch, and Thaler (1991). Ce biais cognitif désigne la résistance aux changements des individus et leur tendance à préférer demeurer dans leur situation initiale. μ représente le coefficient d'aversion au risque des agents et σ^2 , le risque associé à l'utilisation d'une règle de prédiction. En accord avec De Grauwe and Grimaldi (2018), ce risque est défini comme étant le carré de l'erreur de prédiction faite par les agents. Les prédictions étant distinctes selon la règle de

prédiction utilisée, les risques impliqués diffèrent également :

$$\sigma_{c,t}^2 = (E_{t-1}^c[s_t] - s_t)^2 \quad (8)$$

$$\sigma_{f,t}^2 = (E_{t-1}^f[s_t] - s_t)^2 \quad (9)$$

La logique derrière les équations (6) et (7) est la suivante : quand le profit ajusté au risque d'une règle augmente par rapport à celui des autres heuristiques, les agents favorisent l'emploi de cette règle. En conséquence, le pourcentage d'agents adoptant cette dernière augmente. Inversement, si le profit ajusté au risque d'une règle diminue comparativement, la proportion d'agents utilisant cette dernière diminue.

De façon similaire à De Grauwe and Grimaldi (2006) et Béreau (2013), nous définissons le profit (non ajusté au risque) d'une heuristique au temps t comme le profit obtenu en investissant, pour une période, un dollar américain dans l'actif étranger. Plus formellement :

$$\pi_{c,t} = [s_t \cdot (1 + r^*) - s_{t-1} \cdot (1 + r)] \cdot \text{sgn}[(1 + r^*) \cdot E_{t-1}^c[s_t] - (1 + r) \cdot s_{t-1}] \quad (10)$$

$$\pi_{f,t} = [s_t \cdot (1 + r^*) - s_{t-1} \cdot (1 + r)] \cdot \text{sgn}[(1 + r^*) \cdot E_{t-1}^f[s_t] - (1 + r) \cdot s_{t-1}] \quad (11)$$

où

$$\text{sgn}(x) = \begin{cases} 1 & \text{pour } x > 0 \\ 0 & \text{pour } x = 0 \\ -1 & \text{pour } x < 0 \end{cases} \quad (12)$$

En d'autres termes, nous supposons qu'au temps $t - 1$, les agents décident d'investir un dollar dans le marché étranger ou dans le marché domestique. Au temps t , un investissement d'un dollar dans le marché étranger mène à $1 + r^*$ dollars ou de façon équivalente à un montant égal à $s_t \cdot (1 + r^*)$ en monnaie domestique. Inversement, investir s_{t-1} au temps $t - 1$ dans le marché domestique aboutit à un montant $s_{t-1} \cdot (1 + r)$ au temps t . Les agents sélectionnent ensuite une des deux alternatives en comparant les profits attendus des deux stratégies. Selon leur capacité à prédire correctement s_t en $t - 1$, cette décision mène à un gain ou une perte. Par exemple, lorsque les agents prédisent une augmentation du taux de change et que cette augmentation se réalise, leur profit par unité est égal à l'augmentation observée du taux de change (corrigée pour la différence d'intérêt). Inversement, si le taux de change décline, ils font une perte par unité égale à ce déclin. En effet, ils ont, dans ce cas, acheté des actifs étrangers dont la valeur a diminué.

La variation du taux de change attendue en $t + 1$ par l'ensemble des agents opérant sur le marché

est simplement la moyenne pondérée de leurs prédictions au temps t :

$$\begin{aligned} E_t[\Delta s_{t+1}] &= w_{c,t} \cdot \beta(s_t - s_{t-1}) - w_{f,t} \cdot \psi(s_t - s_t^*) \\ &= w_{c,t} \cdot E_t^c[\Delta s_{t+1}] + w_{f,t} \cdot E_t^f[\Delta s_{t+1}] \end{aligned} \quad (13)$$

Dans le modèle, la valeur du taux de change au temps $t + 1$ est déterminée de la façon suivante :

$$s_{t+1} = s_t + E_t[\Delta s_{t+1}] + \tilde{\epsilon}_{t+1} \quad (14)$$

avec $\tilde{\epsilon}_{t+1} \sim \mathcal{N}(0, \sigma_{\tilde{\epsilon}}^2)$ représentant les informations au temps $t + 1$ qui n'ont pas été incorporées dans les prédictions des agents.

3.2. Extensions du modèle de référence

Nous inspirant des travaux de Béreau (2013) et de Georges and Pereira (2021), nous introduisons une nouvelle règle de prédiction dans le modèle présenté ci-dessus. Dans notre première extension, cette nouvelle règle remplace l'heuristique chartiste. Dans notre deuxième extension, la nouvelle heuristique rejoint l'ensemble restreint de règles de prédiction pouvant être employées par les traders. Les agents n'ont cependant pas directement accès à cette nouvelle règle. Celle-ci ne pourra être employée qu'après un certain nombre de périodes pour deux raisons. D'une part, cette nouvelle règle est basée sur des outils d'apprentissage automatique. De tels outils nécessitent un entraînement et ne peuvent donc pas être directement utilisés par les traders (i.e., ils n'ont pas accès à la nouvelle heuristique dès la première de période de trading dans notre marché). D'autre part, une introduction plus tardive permet de comparer les dynamiques observées sur le marché avant et après l'introduction de la nouvelle règle.

Notre nouvelle règle est une forme polynomiale autorégressive estimée à l'aide d'une régression LASSO (Least Absolute Shrinkage and Selection Operator). Nous motivons ce choix de la façon suivante : bien qu'en pratique les traders ne sont pas parfaitement rationnels, il est peu probable que ces derniers ne considèrent pas l'emploi d'outils d'apprentissage automatique et qu'ils ignorent des problèmes tels que le sous-apprentissage (« underfitting » en anglais) et le surapprentissage (« overfitting » en anglais) lorsqu'ils tentent de prédire l'évolution d'actifs financiers. Le problème de sous-apprentissage se présente lorsqu'un modèle performe (très) mal sur les données utilisées pour l'entraîner et sur de nouvelles données. En d'autres termes, peu importe le jeu de données, le modèle n'a pas appris suffisamment et est donc incapable de prédire correctement une variable cible sur base des informations qui lui sont fournies. Le problème de sous-apprentissage est généralement réduit en incorporant de nouvelles variables et/ou en augmentant la complexité du modèle.

Dans le cas du surapprentissage, le modèle réalise de (très) bonnes performances sur les données d'entraînement, mais possède une faible capacité de généralisation et produit, par conséquent, de mauvais résultats sur des données qu'il n'a jamais rencontrées durant son entraînement. Ce problème est particulièrement pertinent de nos jours, car les agents ont accès à une grande puissance de calcul, à de nombreuses variables indépendantes et peuvent facilement combiner ces variables afin de construire des modèles complexes. De plus, comme l'atteste une étude qualitative réalisée par Hansen (2020), les traders semblent être conscients du risque de surapprentissage. En effet, les 31 analystes quantitatifs (ou quants) interviewés par Hansen ont indiqué être préoccupés par ce risque. Tous les quants interrogés travaillaient pour des fonds spéculatifs et des firmes spécialisées dans le trading algorithmique. En incorporant des variables additionnelles dans la nouvelle règle de prédiction et en estimant cette dernière à l'aide d'une régression LASSO, un outil fréquemment utilisé pour réduire le problème de surapprentissage, nous faisons l'hypothèse que les agents utilisant cette règle réalisent les dangers amenés par les problèmes de sous-apprentissage et de surapprentissage et cherchent à les minimiser.

LASSO suppose qu'il n'existe qu'un nombre restreint de prédicteurs pertinents. L'outil sélectionne donc les variables les plus importantes parmi les prédicteurs auxquels le trader a accès. Suivant l'argumentation de Georges and Pereira (2021), nous préférons cet algorithme à d'autres techniques de machine learning plus complexes et plus fréquemment utilisées en finance pour plusieurs raisons. Premièrement, les agents financiers (notamment les investisseurs, les institutions financières et les autorités de régulation) accordent une grande importance à l'interprétabilité de leurs modèles (Bracke et al., 2019 ; Hansen, 2020). Contrairement aux techniques plus complexes qui sont souvent difficiles à interpréter, LASSO facilite la compréhension du modèle en se focalisant sur les meilleures variables indépendantes. Deuxièmement, comparativement à d'autres outils de machine learning, cette méthode affiche généralement une performance correcte (Hastie, Tibshirani, and Friedman, 2009 ; Hastie, Tibshirani, and Wainwright, 2015). Troisièmement, en étant relativement simple à comprendre et à utiliser, LASSO est cohérent avec les hypothèses de rationalité et de puissance de calcul limitées ainsi qu'avec l'utilisation d'heuristiques par les agents présents sur le marché.

La suite de cette section est divisée en deux parties présentant chacune une extension du modèle « à la De Grauwe et Grimaldi » introduit précédemment. De façon similaire à Georges and Pereira (2021) qui ont travaillé sur le modèle multi-agents de Georges (2008), un modèle composé uniquement de chartistes, nous remplaçons les agents chartistes non machine learner de notre modèle de référence par des agents chartistes utilisant des outils d'apprentissage automatique (LASSO). Ce faisant, nous cherchons à mesurer l'impact de ce changement sur la stabilité d'un marché des changes (FOREX) et à confirmer, à l'aide d'un modèle plus élaboré, les résultats obtenus par Georges and

Pereira (2021). Cette première extension suppose le remplacement de tous les agents chartistes au même temps t (i.e., l'adoption d'outils d'apprentissage automatique par les agents chartistes n'est pas progressive, mais se produit pour tous les agents chartistes à un même moment). Cette hypothèse étant très forte, nous proposons une seconde extension de notre modèle de référence. Dans cette seconde extension, notre nouvelle règle de prédiction est une troisième heuristique pouvant être sélectionnée par les agents. Par conséquent, de manière plus réaliste, les agents chartistes n'utilisant pas de méthodes d'apprentissage automatique ne sont pas soudainement éliminés du modèle. En effet, les agents du modèle vont continuer d'adopter les heuristiques délivrant les meilleurs profits. Ainsi, si la nouvelle règle fournit des meilleurs résultats que les autres heuristiques, les agents vont progressivement l'employer.

3.2.1. Remplacement des agents chartistes

Cette première extension correspond au remplacement des agents chartistes tels que définis dans notre modèle de référence par des agents chartistes plus sophistiqués. En effet, bien que ces nouveaux chartistes aient une rationalité limitée, nous supposons qu'ils sont conscients des problèmes de surapprentissage et de sous-apprentissage et emploient des outils de machine learning pour traiter ces derniers. Les agents chartistes se basent toujours sur les variations passées du taux de change. Cependant, ils incorporent un nombre plus important de retards, considèrent des relations non-linéaires via la mise en puissance des variations passées et l'introduction d'interactions entre les différentes variables prises en compte. Leur règle de prédiction est estimée à l'aide d'une régression LASSO. Ainsi, seuls les coefficients associés aux variables les plus pertinentes sont différents de 0 (i.e., grâce à LASSO, ces agents sélectionnent les variables les plus importantes parmi celles considérées). Grâce à l'introduction de nouvelles variables et à la pénalisation apportée par LASSO, ces agents réduisent simultanément les risques de sous-apprentissage et de surapprentissage.

Le remplacement des agents a lieu après un certain nombre de périodes, car les outils d'apprentissage automatique tels que LASSO nécessitent un ensemble de données d'entraînement. Avant l'estimation de la nouvelle règle, le jeu de données d'entraînement est standardisé (les variables indépendantes sont centrées en 0 et leur variance est réduite à 1) afin de réduire le temps d'entraînement et de potentiellement augmenter la précision du modèle. Comme indiqué précédemment, la règle est estimée à l'aide de LASSO, une technique de régularisation permettant d'améliorer l'interprétabilité des résultats. La régularisation permet d'atténuer le risque de surapprentissage en pénalisant la complexité du modèle. Lors de l'estimation des paramètres du modèle, LASSO cherche à minimiser une fonction objectif légèrement différente de la fonction des moindres carrés. En effet, cette fonction objectif contient une pénalité qui s'accroît lorsque la somme des valeurs

absolues des coefficients des variables indépendantes augmente :

$$\text{Fonction objectif} = \sum_{i=1}^n (y_i - \sum_j x_{ij} \cdot \alpha_j)^2 + \lambda \sum_{j=1}^P |\alpha_j| \quad (15)$$

où y_i est la variable dépendante, λ la constante de régularisation, P le nombre de variables indépendantes et $\sum_j x_{ij} \cdot \alpha_j$ la prédiction faite par le modèle.

Plus la valeur de l'hyperparamètre λ est importante, plus la pénalisation est forte. Cette valeur est déterminée à l'aide d'une validation croisée à k blocs spécifiquement adaptée aux séries temporelles (« TimeSeriesSplit »). Une validation croisée « classique » ne peut pas être employée avec des séries temporelles. En effet, les observations ne sont pas indépendantes et ne peuvent donc pas être mélangées de manière aléatoire. Avec « TimeSeriesSplit », les données sont séparées en plusieurs blocs sans être mélangées. Chaque bloc est divisé en deux jeux de données. Le premier (nommé « ensemble d'entraînement ») sert à entraîner le modèle pour les différentes valeurs des hyperparamètres considérées. Ces différentes configurations sont testées sur le second jeu de données (nommé « ensemble de validation ») composant le bloc. L'ensemble d'entraînement du deuxième bloc correspond à l'entièreté du premier bloc de données. Son ensemble de validation est, quant à lui, constitué de nouvelles données et ainsi de suite pour les k blocs considérés (voir figure 3.2.1).

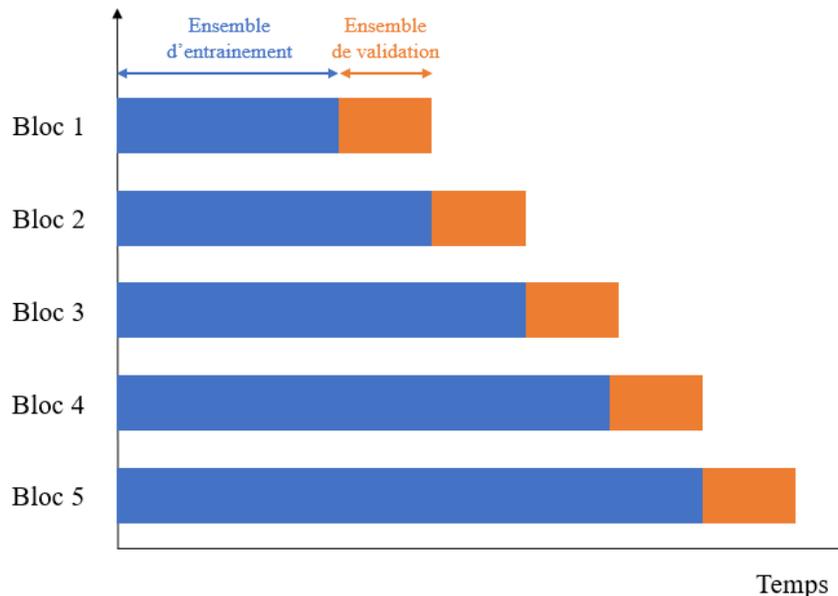


Figure 3.2.1 – Validation croisée à k blocs (« k -fold cross-validation ») pour séries temporelles. Dans notre modèle, k vaut 5 (généralement un k égal à 5 ou à 10 est utilisé).

Lors du remplacement des agents, la règle chartiste devient le produit du paramètre d'extrapolation β et d'une forme polynomiale autorégressive estimée à l'aide de LASSO :

$$E_t^c [\Delta s_{t+1}] = \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) \quad (16)$$

$$E_t^c [s_{t+1}] = s_t + \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) \quad (17)$$

À noter que le paramètre β est conservé afin de pouvoir comparer sans biais l'impact sur la stabilité de l'introduction de la nouvelle règle chartiste.

Par exemple, si les agents chartistes ne considèrent que 3 retards et un polynôme d'ordre deux, leur prédiction de la variation du taux de change est donnée par :

$$E_t^c [\Delta s_{t+1}] = \beta \cdot [\alpha_0 + \alpha_1 \cdot \Delta s_t + \alpha_2 \cdot \Delta s_{t-1} + \alpha_3 \cdot (\Delta s_t)^2 + \alpha_4 \cdot (\Delta s_{t-1})^2 + \alpha_5 \cdot \Delta s_t \cdot \Delta s_{t-1}] \quad (18)$$

L'équation permettant de déterminer la variation du taux de change attendue à la période suivante par les agents opérant sur le marché est modifiée suite au remplacement de la règle chartiste :

$$\begin{aligned} E_t [\Delta s_{t+1}] &= w_{c,t} \cdot \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) - w_{f,t} \cdot \psi(s_t - s_t^*) \\ &= w_{c,t} \cdot E_t^c [\Delta s_{t+1}] + w_{f,t} \cdot E_t^f [\Delta s_{t+1}] \end{aligned} \quad (19)$$

Ces changements mis à part, le modèle demeure similaire.

3.2.2. Ajout des agents chartistes machine learner

Contrairement à l'extension décrite ci-dessus, cette extension ne remplace pas la règle chartiste initialement définie dans notre modèle de référence. En effet, dans cette configuration du modèle, la nouvelle règle chartiste est ajoutée à l'ensemble des heuristiques pouvant être sélectionnées par les agents actifs sur le marché. Cependant, cette nouvelle règle n'est disponible qu'après un certain nombre de périodes afin de permettre sa calibration sur un jeu de données d'entraînement.

Les attentes concernant la variation et la valeur future du taux de change des agents adoptant la nouvelle heuristique sont déterminées de la façon suivante :

$$E_t^m [\Delta s_{t+1}] = \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) \quad (20)$$

$$E_t^m [s_{t+1}] = s_t + \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) \quad (21)$$

où $P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots)$ représente une forme polynomiale autorégressive estimée à l'aide de LASSO.

Le risque associé à l'emploi de cette heuristique est calculé comme suit :

$$\sigma_{m,t}^2 = (E_{t-1}^m[s_t] - s_t)^2 \quad (22)$$

L'introduction d'une nouvelle règle sur le marché impacte le calcul des proportions d'agents utilisant une règle de prédiction spécifique :

$$w_{c,t} = \frac{\exp[\gamma \cdot \pi'_{c,t}]}{\exp[\gamma \cdot \pi'_{c,t}] + \exp[\gamma \cdot \pi'_{m,t}] + \exp[\gamma \cdot \pi'_{f,t}]} \quad (23)$$

$$w_{m,t} = \frac{\exp[\gamma \cdot \pi'_{m,t}]}{\exp[\gamma \cdot \pi'_{c,t}] + \exp[\gamma \cdot \pi'_{m,t}] + \exp[\gamma \cdot \pi'_{f,t}]} \quad (24)$$

$$w_{f,t} = \frac{\exp[\gamma \cdot \pi'_{f,t}]}{\exp[\gamma \cdot \pi'_{c,t}] + \exp[\gamma \cdot \pi'_{m,t}] + \exp[\gamma \cdot \pi'_{f,t}]} \quad (25)$$

Cette nouvelle heuristique affecte également la variation du taux de change attendue à la période suivante par l'ensemble des agents :

$$\begin{aligned} E_t[\Delta s_{t+1}] &= w_{c,t} \cdot \beta (s_t - s_{t-1}) + w_{m,t} \cdot \beta \cdot P(\Delta s_t, \Delta s_{t-1}, \Delta s_{t-2}, \dots) - w_{f,t} \cdot \psi(s_t - s_t^*) \\ &= w_{c,t} \cdot E_t^c[\Delta s_{t+1}] + w_{m,t} \cdot E_t^m[\Delta s_{t+1}] + w_{f,t} \cdot E_t^f[\Delta s_{t+1}] \end{aligned} \quad (26)$$

À l'exception de ces changements, le fonctionnement du modèle est identique à la configuration de référence.

3.3. Méthodologie employée pour l'analyse des résultats

La structure non-linéaire de notre modèle nous contraint à effectuer des simulations numériques afin d'analyser les résultats de nos modèles. En effet, à cause de cette structure, nos modèles ne possèdent pas de solution analytique simple (De Grauwe and Grimaldi, 2018). Les simulations sont réalisées à l'aide de scripts de code en Python. Ces scripts sont disponibles dans les annexes 8.1.1, 8.1.2 et 8.1.3.

Dans ce travail, nous mesurons, d'une part, la pertinence de nos extensions en nous intéressant à leur capacité à reproduire certains faits empiriques observés sur les marchés de change. D'autre part, nous étudions l'impact d'agents chartistes machine learner sur la stabilité des marchés de change en comparant les dynamiques simulées par nos extensions avec celles produites par notre modèle de référence.

Chaque simulation est composée de 10000 observations (aussi appelées périodes). Les 5000 pre-

nières observations sont communes aux trois modèles (modèle de référence et extensions de ce modèle). Ces observations servent à entraîner et calibrer la nouvelle règle de prédiction (règle chartiste plus sophistiquée). Cette règle est introduite à la période 5000. Les prédictions étant faites pour la période suivante, la nouvelle heuristique influence donc le taux de change à partir de la période 5001. Les périodes 5001 à 10000 sont analysées et comparées. Les paramètres utilisés pour la configuration initiale de nos modèles sont présentés dans la table 3.3.1. Cette configuration est similaire à celle utilisée par Béreau (2013). Elle permet au modèle de référence de générer différents faits stylisés ainsi que des périodes de stabilité et d'instabilité (bulles et krachs).

Pour chaque modèle, plusieurs autres configurations sont testées afin d'étudier l'impact d'une variation d'un paramètre sur les résultats obtenus. 100 simulations sont réalisées pour chaque configuration. Néanmoins, au vu du nombre très important de configurations possibles, nous nous focalisons sur les paramètres ayant potentiellement une grande influence sur la capacité des modèles à générer des bulles et des krachs (γ , le paramètre mesurant l'intensité avec laquelle les agents révisent leur règle de prédiction ; β , le paramètre d'extrapolation des agents chartistes ; le nombre de retards considérés dans cette règle). Nous comparons également nos résultats avec ceux issus d'extensions similaires dans lesquelles les agents chartistes machine learner adoptent d'autres outils que LASSO (régression linéaire, Ridge et Elastic Net).

Configuration initiale - Paramètres		
Paramètres	Rôle	Valeur
β	Paramètre d'extrapolation des chartistes	0.9
ψ	Pourcentage de mauvais alignement attendu à être corrigé	0.2
μ	Coefficient d'aversion au risque	0.5
γ	Intensité avec laquelle les agents révisent leur règle de prédiction	5
$w_{c,0}$	Proportion d'agents chartistes à la période 0	0.5
$w_{f,0}$	Proportion d'agents fondamentalistes à la période 0	0.5
r	Taux d'intérêt domestique	0
r^*	Taux d'intérêt étranger	0
s_0	Taux de change initial	0
s_0^*	Valeur fondamentale initiale du taux de change	0
Degree_poly	Degré de la règle de prédiction ML	3
Number_lags	Nombre de retards introduits dans la règle de prédiction ML	4
Number_train	Nombre de périodes utilisées pour la calibration de la règle ML	5000
Number_obs	Nombre d'observations/périodes par simulation	10000

Table 3.3.1 – Paramètres utilisés pour les configurations initiales de nos modèles.

Dans les deux sous-sections suivantes, nous détaillons les méthodes employées pour tester la pertinence de nos extensions et pour étudier l'impact des agents chartistes machine learner sur la stabilité des marchés de change.

3.3.1. Pertinence des modèles

Nous nous intéressons à la capacité de notre extension à générer les mêmes faits stylisés que le modèle « à la De Grauwe et Grimaldi » que nous utilisons comme référence. Les faits stylisés d'intérêt sont les suivants :

1. les clusters de volatilité dans les rendements (« volatility clustering » en anglais);
2. les queues de distribution épaisses pour les rendements (« fat tails »);
3. l'excès de volatilité (« excess volatility »);
4. la déconnexion du taux de change des variables fondamentales sous-jacentes (« disconnect puzzle »).

De brèves explications de ces régularités empiriques et des tests employés sont données ci-dessous.

Clusters de volatilité

De nombreux articles ont mis en avant une dépendance temporelle au niveau de la volatilité des rendements des taux de change (notamment Cont (2002); Lux and Marchesi (1998); Mandelbrot (1963)). Nous testons la présence de cette dépendance dans nos simulations à l'aide d'un test ARCH de Engle (« Engle's Test for Autoregressive Conditional Heteroscedasticity »). Afin de réaliser ce test, nous estimons d'abord un modèle à rendement espéré constant (« constant expected return model »). L'hypothèse nulle du test ARCH de Engle suppose l'homoscédasticité des résidus de ce modèle. L'hypothèse alternative est que les résidus sont hétéroscedastiques. Rejeter l'hypothèse nulle indique la présence de clusters de volatilité dans les rendements.

Queues de distribution épaisses

Les rendements de la plupart des actifs financiers ne sont pas normalement distribués. Leurs distributions affichent généralement des queues plus épaisses et une densité plus importante autour de la moyenne que la distribution normale. Comme l'ont notamment démontré Koedijk, Stork, and de Vries (1992), de Vries (2001), Palm et al. (2002) et Lux and Alfarano (2016), les taux de change n'y font pas exception. Nous examinons la non-normalité des rendements simulés à l'aide d'un test de Jarque-Bera. L'hypothèse nulle de ce test est que les données sont normalement distribuées. Inversement, l'hypothèse alternative est que les données ne sont pas normalement distribuées.

Nous analysons plus spécifiquement la présence de queues de distribution épaisses en estimant le kurtosis des rendements et en testant pour chaque simulation si ce kurtosis est significativement plus important que celui d'une distribution normale (i.e., significativement supérieur à 3). Nous procédons donc à des tests unilatéraux à droite.

Excès de volatilité

L'excès de volatilité est une régularité empirique des marchés de change (Baxter and Stockman, 1989; Flood and Rose, 1995). Elle désigne le fait que la volatilité du taux de change est largement supérieure à la volatilité des variables économiques sous-jacentes. Nos modèles ne comportent qu'une variable économique sous-jacente : la valeur fondamentale du taux de change. Suivant De Grauwe and Grimaldi (2006), nous mesurons la présence de cette régularité dans nos simulations à l'aide du « noise to signal ratio ».

Nous pouvons décomposer la volatilité du taux de change en deux. D'une part, la variance liée à la volatilité de la valeur fondamentale du taux de change. D'autre part, la variance résiduelle du taux de change, aussi appelée le bruit :

$$variance(s) = variance(s^*) + variance(bruit) \quad (27)$$

$$\Leftrightarrow variance(bruit) = variance(s) - variance(s^*) \quad (28)$$

Le « noise to signal ratio » nous indique l'importance du bruit (« noise ») produit par le modèle par rapport à la volatilité de la valeur fondamentale du taux de change (« signal »). Le « noise to signal ratio » est calculé de la façon suivante :

$$noise\ to\ signal\ ratio = \frac{variance(bruit)}{variance(s^*)} = \frac{variance(s)}{variance(s^*)} - 1 \quad (29)$$

Un ratio supérieur à 1 indique que la volatilité du taux de change est composée majoritairement de volatilité non liée à la volatilité de sa valeur fondamentale. Autrement dit, la volatilité du taux de change est majoritairement constituée par du bruit.

Déconnexion du taux de change

Plusieurs auteurs (notamment Faust et al., 2003; Goodhart, 1989; Goodhart and Figliuoli, 1991) ont montré que la plupart des variations observées au niveau des taux de change se produisent alors qu'il n'y a pas de changement observable dans les variables économiques sous-jacentes. En effet, les taux de change semblent très souvent déconnectés de leurs variables fondamentales. Cette régularité empirique, analysée initialement par Williamson (1985) et popularisée par Obstfeld and Rogoff (2000), est communément appelée le « disconnect puzzle ». Pour chaque simulation, nous réalisons une analyse de cointégration entre le taux de change et sa valeur fondamentale afin de confirmer la réplique de ce fait empirique par notre extension. L'absence de cointégration entre les deux variables indique la réplique du fait stylisé. Notre analyse est basée sur le test en deux étapes de Engle-Granger. L'hypothèse nulle de ce test suppose l'absence de cointégration entre les deux variables. Cette hypothèse est rejetée si la p-value du test est inférieure au seuil de significativité

fixé. Nous considérons un seuil de significativité de 5 % dans ce mémoire.

3.3.2. Impact des agents machine learner sur la stabilité des marchés

Nous investiguons l'impact des agents machine learner en comparant les dynamiques du taux de change observées pour le modèle de référence et les extensions de ce modèle. Cette comparaison est faite via une analyse graphique et des tests de comparaison de moyennes pour différentes mesures visant à quantifier le nombre de périodes d'instabilité, les fréquences et les durées des bulles et des krachs. Deux types de tests de comparaison de moyennes sont utilisés. Le test de Student, un test paramétrique, est utilisé lorsque ses hypothèses sont respectées (homogénéité des variances des deux groupes et normalité). L'hypothèse d'homogénéité des variances est vérifiée à l'aide d'un test de Levene. Une p-value inférieure à 0,05 (seuil de significativité de 5 %) indique que les variances des deux groupes ne sont pas homogènes. Nous utilisons un test de Shapiro-Wilk pour nous assurer du respect de l'hypothèse de normalité. Pour ce test, une p-value inférieure à 0,05 (seuil de significativité à 5 %) indique un rejet de l'hypothèse nulle du test. En d'autres termes, il est peu probable que les données soient issues d'une population normalement distribuée si l'hypothèse nulle du test est rejetée. Lorsqu'au moins une des conditions du test de Student n'est pas remplie, nous utilisons le test de Wilcoxon, un test de comparaison de moyennes non paramétrique.

Notre première mesure est la moyenne quadratique des écarts entre le taux de change et sa valeur fondamentale. Des valeurs plus importantes pour cette mesure indiquent une plus grande instabilité sur le marché. D'un point de vue mathématique :

$$Mesure\ 1 = \sqrt{\frac{1}{T} \sum_{t=1}^T (s_t - s_t^*)^2} \quad (30)$$

où s_t est le taux de change à la période t , s_t^* sa valeur fondamentale à la période t , T le nombre de périodes considérées (l'ensemble des périodes après le remplacement des chartistes ou l'ajout de la nouvelle heuristique).

Notre deuxième mesure est une mesure proposée par De Grauwe and Grimaldi. Avec celle-ci, une période est comptabilisée comme une période d'instabilité si tous les écarts en valeur absolue entre le taux de change et sa valeur fondamentale pour les 20 dernières périodes (la période courante et les 19 périodes précédentes) sont égaux ou supérieurs à l'écart-type de la valeur fondamentale⁶ multiplié par 3. En d'autres termes, une période est considérée comme une période d'instabilité si le taux de change dévie fortement de sa valeur fondamentale depuis un certain intervalle de temps (20 jours en comptant la période actuelle). Une distinction entre les périodes de bulle et les périodes de

6. Cet écart-type est calculé sur la période suivant l'introduction de la nouvelle heuristique ou le remplacement des agents chartistes.

krach peut être réalisée : une période de bulle (resp. krach) est une période pour laquelle l'écart entre le taux de change et sa valeur fondamentale, ainsi que tous les écarts des 19 périodes précédentes sont supérieurs (resp. inférieurs) ou égaux à l'écart-type de la valeur fondamentale multiplié par 3.

Sur base de cette mesure, nous sommes également capable de déterminer le nombre de bulles et de krachs se produisant au cours d'une simulation : lorsqu'une période de bulle (resp. krach) se produit, si la période précédente n'était pas considérée comme une période de bulle (resp. krach), le nombre de bulles (resp. krachs) augmente de 1. Si la période précédente était une période de bulle (resp. krach), le nombre de bulles (resp. krachs) n'augmente pas. Ainsi, nous pouvons comparer le nombre de krachs et de bulles ainsi que le nombre de périodes de bulle et de krach générées par nos modèles.

Nous calculons les durées moyennes des bulles et des krachs en ne retenant que les simulations pour lesquelles des périodes de bulle et/ou de krach ont été observées. Pour chacune de ces simulations, la durée moyenne des bulles (resp. krachs) est obtenue en divisant le nombre de périodes de bulle (resp. krach) par le nombre de bulles (resp. krachs). Les durées moyennes des bulles et des krachs sont déterminées en calculant la moyenne de résultats obtenus pour l'ensemble des simulations considérées.

4. Analyse des résultats

Nous présentons les résultats de nos simulations dans cette section. Dans un premier temps, nous nous intéressons à chaque extension de manière individuelle. Nous évaluons d’abord la pertinence de l’extension en testant sa capacité à répliquer les faits empiriques pouvant être reproduits par le modèle de référence. Ensuite, nous analysons l’impact des agents chartistes machine learner sur la stabilité des marchés de change en comparant les dynamiques générées par l’extension avec les dynamiques produites par le modèle de référence. Enfin, nous examinons la sensibilité de nos résultats concernant l’impact des agents machine learner en faisant varier la valeur de certains paramètres et en changeant le type d’outil utilisé pour la nouvelle règle de prédiction (LASSO, régression linéaire, Ridge, ou Elastic Net). Dans un second temps, nous comparons les résultats de nos deux extensions.

4.1. Remplacement des agents chartistes

4.1.1. Pertinence du modèle

Clusters de volatilité

Pour rappel, nous testons la présence de clusters de volatilité dans les rendements à l’aide de tests ARCH de Engle. Ce test évalue la présence d’autocorrélation dans les résidus au carré d’un modèle estimé au préalable (un modèle à rendement espéré constant dans notre cas) en considérant un certain nombre de retards. Nous considérons 40 retards pour ces tests (i.e., le nombre de retards sélectionné par défaut par le module utilisé pour procéder à ce test). Cette valeur a été déterminée de manière arbitraire pour éviter d’avoir à estimer le nombre de retards optimal à tester pour chaque simulation. La présence d’autocorrélation dans les résidus au carré du modèle indique que ces derniers sont hétéroscédastiques (i.e., présence de clusters de volatilité).

Toutes les simulations effectuées pour la configuration initiale du modèle rejettent l’hypothèse nulle d’absence d’autocorrélation des résidus à un seuil de significativité de 5 %. Cela indique que notre modèle est capable de répliquer les clusters de volatilité observés sur les marchés de change.

Néanmoins, comme le montre la figure 4.1.1, le phénomène de « volatility clustering » semble moins marqué pour notre extension que pour le modèle de référence. Nous observons également une volatilité moyenne des rendements plus faible pour l’extension (voir table 4.1.1).

Queues de distribution épaisses

Le test de Jarque-Bera nous permet de tester si les rendements sont normalement distribués (kurtosis = 3 et skewness = 0). Nous procédons à ce test pour les 100 simulations de notre extension et du modèle de référence.

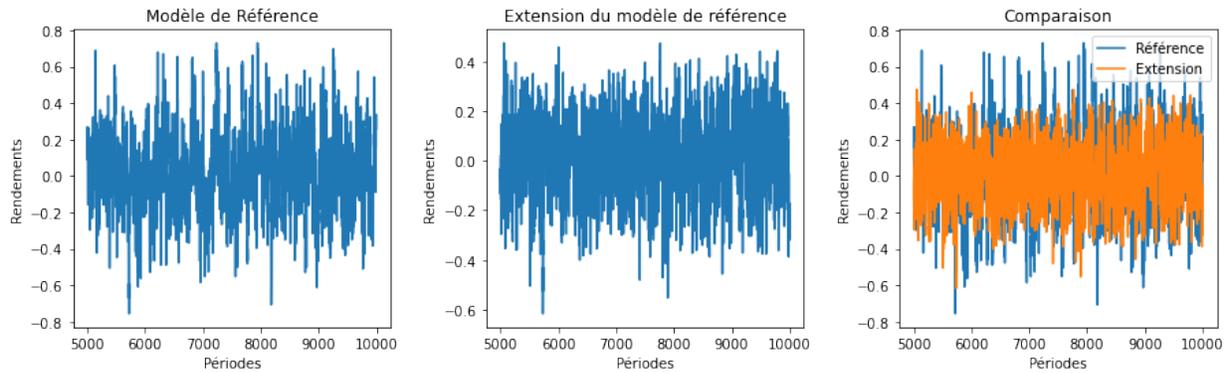


Figure 4.1.1 – Évolution et comparaison des rendements de nos différents modèles après le remplacement de la règle chartiste. La simulation sélectionnée pour les graphes est représentative des résultats généraux.

	Minimum	Maximum	Moyenne	Variance	Skewness	Excès de Kurtosis
Moyenne - Référence	-0.86	0.86	0	0.04	0.01	1.22
Moyenne - Extension	-0.49	0.48	-0	0.02	-0.01	0.16
Levene p-value	0.05	0.03	0	0	0	0
Shapiro-Wilk p-value	0	0	0	0	0.01	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0.24	0	0.44	0

Table 4.1.1 – Comparaison de statistiques descriptives des rendements générés par les deux modèles. Nous utilisons des tests unilatéraux. L’hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l’extension.

Les résultats des tests de Jarque-Bera indiquent que les rendements de la majorité des simulations de notre extension (62 sur 100) suivent une loi normale (non-rejet de l'hypothèse nulle à un seuil de significativité de 5 %). Nous testons également de manière plus spécifique la présence d'excès de kurtosis strictement supérieur à 0 (test unilatéral à droite). 44 simulations présentent un excès de kurtosis strictement supérieur à 0. Ces deux tests indiquent que nos simulations n'affichent pas de queues de distribution épaisses (kurtosis significativement supérieur à 3) dans la majorité des cas. Notre extension est donc incapable de reproduire de manière systématique la présence de queues de distribution épaisses pour les rendements.

Contrairement à notre extension, le modèle de référence « à la De Grauwe et Grimaldi » génère de manière quasiment systématique ce fait empirique. En effet, pour 87 simulations sur 100, la distribution des rendements possède des queues de distribution plus épaisses que la loi normale.

Excès de volatilité

Nous calculons le « noise to signal ratio » pour évaluer la présence d'excès de volatilité dans nos simulations (i.e., tester si la volatilité du taux de change est largement supérieure à celle de sa valeur fondamentale). Un ratio supérieur à 1 indique la présence d'excès de volatilité.

Contrairement au modèle de référence (80 simulations sur 100), la plupart de nos simulations ne présentent pas un « noise to signal ratio » supérieur à 1 (seules 24 simulations possèdent un ratio supérieur à 1). Cela montre une incapacité de notre extension à reproduire ce fait stylisé pour la plupart des simulations.

Comme le montre la table 4.1.2, le ratio moyen des simulations de notre extension est égal à 9,18. Cette valeur est largement supérieure à 1. Cela indique que lorsque les simulations génèrent le fait empirique, la proportion de la volatilité du taux de change lié au bruit est largement supérieure à la proportion liée à la valeur fondamentale du taux de change. La table 4.1.2 met également en évidence que le ratio moyen des simulations du modèle de référence est significativement supérieur au ratio moyen obtenu pour l'extension de ce modèle.

	Noise to signal ratio
Moyenne - Référence	85.05
Moyenne - Extension	9.18
Levene p-value	0
Shapiro-Wilk p-value	0
Test	Wilcoxon
Test p-value	0

Table 4.1.2 – Comparaison des valeurs moyennes du « noise to signal ratio ». Nous utilisons un test unilatéral. L'hypothèse nulle de ce test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

Déconnexion du taux de change

Le taux de change généré par notre extension ne semble pas être déconnecté de sa valeur fondamentale pour la majorité des simulations. En effet, l'hypothèse nulle d'absence de cointégration du test d'Engle-Granger est rejetée pour 55 simulations sur 100. Notre extension ne reproduit donc pas de manière systématique le « disconnect puzzle ».

Bien que générant ce fait stylisé dans la majorité des cas (non-rejet de l'hypothèse nulle pour 60 simulations sur 100), le modèle de référence semble également éprouver des difficultés à le répliquer de manière systématique.

Conclusion sur la pertinence de l'extension

La reproduction de faits empiriques par un modèle à agents hétérogènes est un gage de sa qualité. Malheureusement, notre première extension ne permet de reproduire de manière systématique qu'un seul des faits stylisés répliqués par notre modèle de référence : les clusters de volatilité. En ce sens, la pertinence de notre extension est moindre par rapport au modèle de référence.

Néanmoins, cette incapacité à reproduire certaines régularités empiriques de manière systématique ne dessert pas forcément notre étude. En effet, nous cherchons principalement à étudier l'impact des agents machine learner sur la stabilité des marchés de change. Or, les faits stylisés peuvent être considérés comme des anomalies par rapport à l'hypothèse d'efficience des marchés. D'une part, en étant capable de reproduire les faits stylisés d'intérêt pour un nombre de simulations plus faible que le modèle de référence, notre extension semble indiquer que le remplacement des agents chartistes par des agents machine learner permet d'améliorer l'efficience des marchés et, par conséquent, leur stabilité. D'autre part, le modèle reste capable de générer les régularités empiriques d'intérêt et justifie ainsi sa pertinence par rapport aux phénomènes observés sur les marchés.

4.1.2. Impact des agents machine learner sur la stabilité des marchés

Dans cette sous-section, nous analysons l'impact du remplacement des agents chartistes tels que définis dans le modèle de référence par des agents chartistes machine learner. Ceux-ci sont conscients des problèmes de sous-apprentissage et de surapprentissage et utilisent LASSO pour estimer leur règle de prédiction. Afin d'évaluer l'impact de ce remplacement, nous procédons d'abord à une analyse graphique. Ensuite, nous calculons et comparons différentes mesures d'instabilité pour les simulations de notre extension et du modèle de référence.

Nous pouvons nous faire une première opinion concernant les conséquences du remplacement des agents chartistes en observant graphiquement l'évolution du taux de change. Les dynamiques de la plupart des simulations sont similaires à celles présentées par la figure 4.1.2. Cette figure nous montre l'évolution du taux de change pour notre modèle de référence et notre extension. Comme

pressenti lors de l'analyse de la pertinence de l'extension, la nouvelle règle de prédiction semble stabiliser les marchés. En effet, le taux de change simulé par notre extension paraît en moyenne plus proche de sa valeur fondamentale que celui généré par le modèle de référence. Nous observons également moins de périodes d'instabilité (périodes pour lesquelles le taux de change s'éloigne fortement de sa valeur fondamentale).

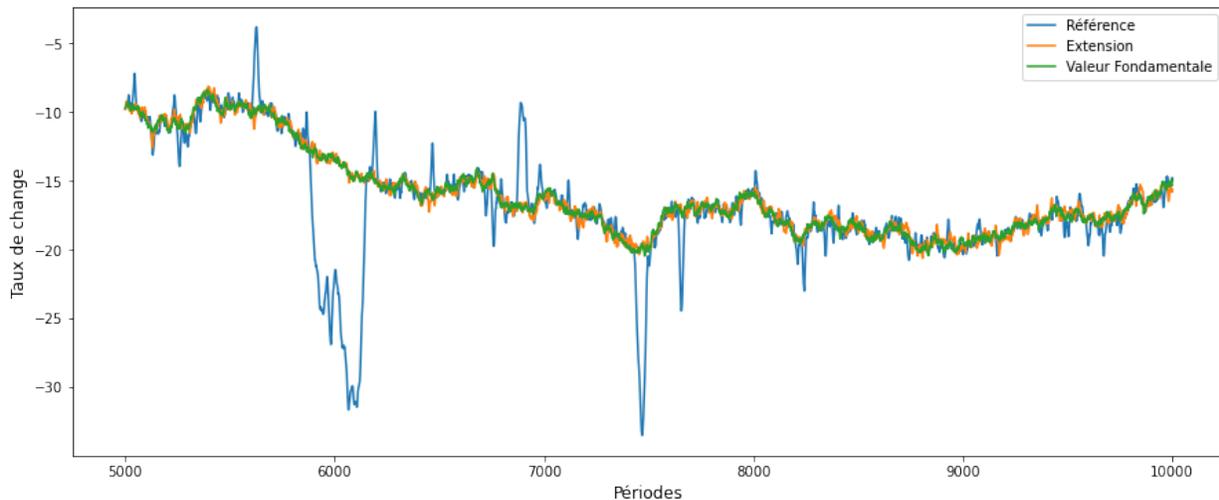


Figure 4.1.2 – Comparaison des dynamiques du taux de change générées par l'extension (remplacement des agents chartistes) et par le modèle de référence.

Cependant, cette stabilité accrue n'est pas constatée pour toutes les simulations. En effet, les marchés semblent plus instables pour un ensemble minoritaire de simulations. Dans ces simulations, le taux de change généré par notre extension affiche peu de variations, mais reste éloigné de sa valeur fondamentale pour un nombre important de périodes. La stabilité du marché après le remplacement des agents chartistes semble dépendante de l'état du marché (stable, bulle ou krach) durant la période précédant le remplacement. En effet, lorsque le remplacement a lieu durant une période de stabilité, le marché demeure stable (pas de bulle ni de krach, voir figure 4.1.3). Lorsque le remplacement des agents se déroule durant une période de bulle ou de krach, le taux de change varie relativement peu. En conséquence, il se rapproche difficilement de sa valeur fondamentale (voir figure 4.1.4 et figure 4.1.5). En d'autres termes, lorsque le remplacement de l'heuristique a lieu pendant une période d'instabilité, le marché semble sous-estimer ou surestimer la valeur du taux de change par rapport à sa valeur fondamentale pour des laps de temps très importants. Le remplacement de l'heuristique chartiste semble donc réduire fortement la variance du taux de change. Cela affecte la capacité du modèle à générer de nouvelles périodes d'instabilité (bulles ou krachs) et à se remettre de ces périodes.

Comme l'illustrent également les figures 4.1.3, 4.1.4 et 4.1.5, les périodes d'instabilité (bulles ou krachs) des deux modèles sont caractérisées par l'utilisation (quasiment) exclusive de l'heuris-

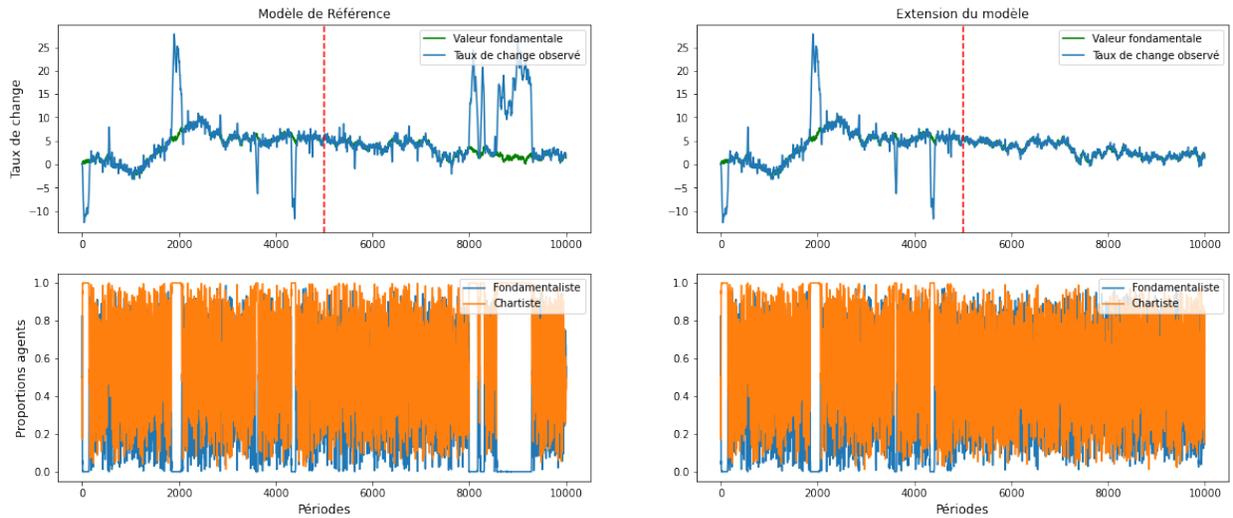


Figure 4.1.3 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (remplacement des agents chartistes) et le modèle de référence - Exemple de stabilité introduite par la nouvelle heuristique. La ligne verticale rouge correspond à la période durant laquelle le remplacement des agents chartistes se produit.

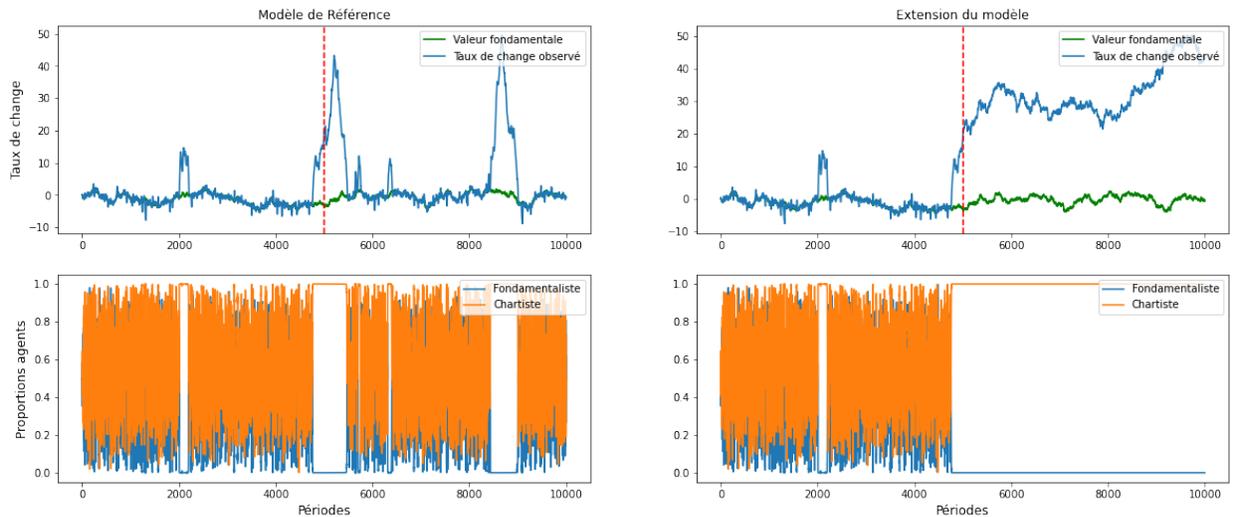


Figure 4.1.4 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (remplacement des agents chartistes) et le modèle de référence - Exemple de période d’instabilité prolongée suite au remplacement : pas de retour à l’équilibre - La ligne verticale rouge correspond à la période durant laquelle le remplacement des agents chartistes se produit.

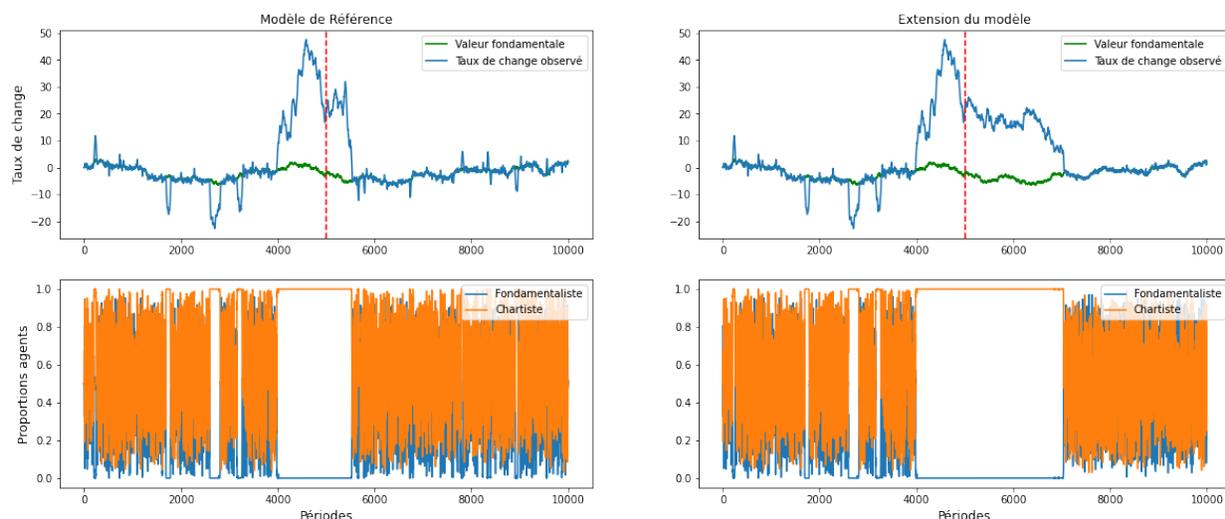


Figure 4.1.5 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (remplacement des agents chartistes) et le modèle de référence - Exemple de période d’instabilité prolongée vers la valeur fondamentale suite au remplacement de l’heuristique chartiste : retour à l’équilibre - La ligne verticale rouge correspond à la période durant laquelle le remplacement des agents chartistes se produit.

tique chartiste. Durant les périodes de stabilité, il existe une hétérogénéité au niveau des règles de prédiction employées par les agents. Pendant ces périodes, les proportions d’agents utilisant une heuristique spécifique varient significativement au cours du temps. Ces résultats sont similaires à ceux obtenus par De Grauwe and Grimaldi (2005a).

De Grauwe and Grimaldi expliquent la formation de bulles et de krachs ainsi que l’élimination des agents fondamentalistes durant ces périodes d’instabilité de la façon suivante : quand le taux de change évolue de manière continue dans une direction (à la hausse ou à la baisse), les règles à feedback positif (la règle chartiste dans notre modèle) deviennent plus profitables. Inversement, dans de telles situations, les agents utilisant des règles à feedback négatif (les agents fondamentalistes de notre modèle) font d’importantes erreurs de prédiction. Cela réduit leurs profits et augmente leurs risques. En conséquence, la proportion d’agents utilisant la règle chartiste augmente. L’accroissement du nombre d’agents chartistes entretient la tendance à la hausse ou à la baisse, qui provoque à son tour une augmentation de la proportion de chartistes sur le marché de change. Cette dynamique se poursuit jusqu’à l’élimination totale des agents fondamentalistes du marché (i.e., tous les agents adoptent l’heuristique chartiste). À partir de ce moment, l’évolution à la hausse ou la baisse du taux de change ralentit⁷. Cette perte de vitesse réduit l’erreur de prédiction de la règle fondamentaliste, ce qui augmente le profit relatif de l’heuristique. Un choc exogène, généralement dans la valeur fondamentale du taux de change, peut alors provoquer un rapide retour des agents

7. Ce ralentissement a lieu car le paramètre d’extrapolation des agents chartistes est inférieur à 1.

fondamentalistes sur le marché et ainsi mettre fin à la période d'instabilité.

Comme indiqué précédemment, le remplacement de l'heuristique chartiste de notre modèle de référence par une règle de prédiction chartiste plus sophistiquée semble fortement réduire la variance du taux de change ainsi que la capacité du modèle à générer et à sortir d'une période d'instabilité. Cela est probablement dû au nombre plus important de variables considérées par les agents chartistes ainsi qu'à la sélection des prédicteurs les plus pertinents parmi cet ensemble de variables. Cela semble leur permettre de commettre de plus faibles erreurs de prédiction que les agents chartistes avant remplacement. Ainsi, lorsque le taux de change traverse une période d'instabilité (i.e., lorsqu'aucun agent présent sur le marché n'utilise l'heuristique fondamentaliste), le profit relatif de l'heuristique chartiste demeure relativement stable, ne permettant pas ou difficilement le retour des fondamentalistes sur le marché et donc le retour du taux de change vers sa valeur fondamentale. Durant une période de stabilité, les agents fondamentalistes sont présents sur le marché. En prenant en compte plus de variables qu'auparavant, les chartistes anticipent une évolution du taux de change relativement stable. En conséquence, les fondamentalistes font de faibles erreurs de prédiction, ce qui empêche leur élimination du marché. Les agents employant la nouvelle heuristique chartiste semblent donc difficilement capables d'expulser les fondamentalistes du marché. De ce fait, le taux de change reste proche de sa valeur fondamentale.

Nous confirmons notre analyse graphique grâce à différentes mesures et tests de comparaison de moyennes unilatéraux. Nous fixons le seuil de significativité à 5 % pour ces tests. Comme présenté durant l'analyse graphique, la variance du taux de change est en moyenne significativement plus faible pour notre extension que pour le modèle de référence. En effet, la p-value du test de Wilcoxon est égale à 0 (voir table 4.1.3). Les valeurs maximales et minimales du taux de change sont également moins extrêmes en moyenne pour notre extension (p-values également égales à 0).

	Minimum	Maximum	Moyenne	Variance
Moyenne - Référence	-33.22	30.14	-1.51	374.66
Moyenne - Extension	-16	3.83	-6.39	44.42
Levene p-value	0.07	0.03	0.59	0
Shapiro-Wilk p-value	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0.93	0

Table 4.1.3 – Minimum, maximum, moyenne et variance moyens observés pour le modèle de référence et pour notre extension (remplacement des agents chartistes) pour les périodes suivant le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

La moyenne quadratique des écarts entre le taux de change et sa valeur fondamentale est en moyenne significativement plus faible pour notre extension (p-value du test unilatéral de Wilcoxon égale à 0, voir table 4.1.4). Cette première mesure d'instabilité confirme notre analyse graphique : l'utilisation d'outils d'apprentissage automatique par les agents chartistes semble stabiliser les marchés de change.

	Moyenne quadratique des écarts
Moyenne - Référence	24.27
Moyenne - Extension	14.65
Levene p-value	0.17
Shapiro-Wilk p-value	0
Test	Wilcoxon
Test p-value	0

Table 4.1.4 – Comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes suivant le remplacement des agents. Nous utilisons un test unilatéral. L'hypothèse nulle de ce test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

Comme l'indique notre seconde mesure, le nombre de périodes d'instabilité est significativement réduit après le remplacement des agents chartistes (p-value du test inférieure à 0,05, voir table 4.1.5). Pour rappel, cette mesure identifie une période comme étant une période d'instabilité si l'écart entre le taux de change et sa valeur fondamentale a toujours été supérieur ou égal à une valeur de référence (l'écart-type de la valeur fondamentale multiplié par trois) sur une fenêtre de 20 observations (la période courante et les 19 périodes précédentes).

Les nombres moyens de périodes de bulle et de périodes de krach sont significativement plus faibles pour notre extension que pour le modèle de référence (p-values des tests unilatéraux inférieures à 0,05, voir table 4.1.5). Les simulations de notre extension génèrent en moyenne plus de périodes de krach que de périodes de bulle. Ce résultat est probablement dû au caractère aléatoire de nos simulations et à la difficulté de notre extension à sortir d'une période d'instabilité. En effet, le nombre de simulations dans lesquelles les agents sont remplacés durant un krach est supérieur au nombre de simulations dans lesquelles l'heuristique chartiste est remplacée durant une bulle.

Sans surprise, le remplacement des agents chartistes réduit en moyenne le nombre de bulles et de krachs de manière significative (p-values égales à 0 pour les tests unilatéraux, voir table 4.1.6). Cependant, les durées moyennes des bulles et des krachs sont bien plus importantes pour notre extension (voir table 4.1.7). Les p-values de nos tests unilatéraux⁸ indiquent que les différences sont significatives (p-values inférieures à 0,05 et égales à 0). La durée moyenne des krachs générés

8. Contrairement à nos tests précédents, l'hypothèse nulle est ici que la valeur moyenne observée pour le modèle de référence est supérieure ou égale à la valeur moyenne de l'extension.

par notre extension est largement supérieure à celle des bulles. De nouveau, cela est probablement dû au caractère stochastique de nos simulations.

	Périodes d'instabilité	Périodes de bulle	Périodes de krach
Moyenne - Référence	1584.1	707.66	876.44
Moyenne - Extension	1155.63	382.28	773.35
Levene p-value	0.46	0.07	0.68
Shapiro-Wilk p-value	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0

Table 4.1.5 – Comparaison des nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach pour l'extension et le modèle de référence. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nombre de bulles	Nombre de krachs
Moyenne - Référence	1.04	1.18
Moyenne - Extension	0.23	0.16
Levene p-value	0	0
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0	0

Table 4.1.6 – Comparaison des nombres moyens de bulles et de krachs pour l'extension et le modèle de référence. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Durée des bulles	Durée des krachs
Moyenne - Référence	973.6	974.85
Moyenne - Extension	2780.92	4833.44
Levene p-value	0.02	0.03
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0	0

Table 4.1.7 – Comparaison des durées moyennes des bulles et des krachs pour l'extension et le modèle de référence. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

Pour résumer les résultats de cette sous-section, le remplacement des agents chartistes initiaux par des agents chartistes machine learner semble en moyenne stabiliser les marchés de change en réduisant le nombre de périodes d'instabilité par simulation et les fréquences des bulles et des krachs. Cependant, la durée moyenne des périodes d'instabilité augmente considérablement avec le remplacement des agents. Cela est dû à la difficulté de notre extension à sortir d'une bulle ou d'un krach.

4.1.3. Analyse de sensibilité

Dans cette sous-section, nous analysons la sensibilité de nos résultats aux valeurs sélectionnées pour certains paramètres du modèle. Le nombre de paramètres pour notre extension étant conséquent, nous nous focalisons sur quatre d'entre eux : le degré d'extrapolation des agents chartistes (β), la sensibilité des agents à la rentabilité des heuristiques (γ), le nombre de retards considérés par les agents chartistes machine learner et l'algorithme utilisé par ceux-ci. Nous nous intéressons spécifiquement à l'influence de ces paramètres sur la stabilité des marchés de change simulés.

Degré d'extrapolation des agents chartistes

Nous nous intéressons d'abord au paramètre β du modèle. Ce paramètre correspond au degré d'extrapolation des agents chartistes. Une valeur plus importante de ce paramètre indique que les agents chartistes prédisent de manière plus agressive le futur à partir des valeurs passées du taux de change. En d'autres termes, le caractère déstabilisant des agents chartistes du modèle s'accroît lorsque β augmente. Suivant De Grauwe and Grimaldi, nous testons des valeurs strictement comprises entre 0 et 1⁹ (0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 0,8, 0,9). Dans notre configuration initiale, β valait 0,9.

Pour toutes les valeurs de β testées, la valeur moyenne des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale est significativement plus faible pour notre extension que pour notre modèle de référence (voir Annexe 8.2.1). Cette valeur moyenne augmente avec β et est relativement faible pour les valeurs de β strictement inférieures à 0,9. Le taux de change est donc en moyenne relativement proche de sa valeur fondamentale pour ces valeurs du paramètre d'extrapolation. En conséquence, nous nous attendons à constater en moyenne une plus grande stabilité pour les valeurs de β testées inférieures ou égales à 0,8.

Comme nous le montrons ci-dessous, cette intuition est confirmée par nos autres mesures d'instabilité. En effet, les deux modèles semblent incapables de générer des périodes d'instabilité pour un β inférieur ou égal à 0,7 (voir Annexes 8.2.2, 8.2.3 et 8.2.4). De façon surprenante, la présence des agents machine learner ne semble pas réduire le nombre de périodes d'instabilité (bulles et krachs) pour β égal à 0,8. Cela est également vrai lorsque nous considérons de manière séparée le nombre de périodes de bulle et le nombre de périodes de krach. En effet, dans les trois cas, nous ne pouvons pas rejeter l'hypothèse nulle spécifiant que la moyenne obtenue pour les simulations du modèle de référence est inférieure ou égale à la moyenne obtenue pour l'extension du modèle. Des résultats similaires sont obtenus pour les nombres moyens de bulles et de krachs (voir Annexes 8.2.5 et 8.2.6).

Les résultats concernant la durée moyenne des bulles peuvent uniquement être étudiés pour un paramètre d'extrapolation égal à 0,9 (voir Annexe 8.2.7). En effet, les deux modèles ne produisent

9. Des valeurs strictement comprises entre 0 et 1 assurent la stabilité des dynamiques.

pas de bulles pour les valeurs testées inférieures ou égales à 0,7. De plus, pour une valeur de 0,8, des bulles sont uniquement observées pour notre modèle de référence. Un test de comparaison est donc impossible pour ces valeurs.

Nous faisons face à des problèmes similaires pour les durées moyennes des krachs. Néanmoins, notre extension produit des krachs lorsque β vaut 0,8. Pour cette valeur, la durée moyenne des krachs de notre extension est supérieure à celle des krachs du modèle de référence. Cependant, cette différence n'est pas significative (p-value supérieure à 0,05, voir Annexe 8.2.8).

En conclusion, le paramètre d'extrapolation des agents chartistes influence grandement la capacité de nos modèles à produire des bulles et des krachs et, par conséquent, nos résultats. Néanmoins, le remplacement des agents chartistes réduit en moyenne l'écart moyen entre le taux de change et sa valeur fondamentale pour toutes les valeurs de β testées. En ce sens, les agents chartistes machine learner semblent permettre une plus grande efficacité et stabilité des marchés.

Sensibilité des agents à la profitabilité des heuristiques

Le paramètre γ définit la propension des agents à réviser leur règle de prédiction. Lorsque la valeur de ce paramètre augmente, les agents ont tendance à changer plus rapidement d'heuristique. Durant cette analyse de sensibilité, nous considérons six valeurs pour γ : 0, 1, 2, 5, 10, 20¹⁰.

Comme le montre l'annexe 8.2.9, la valeur moyenne des moyennes quadratiques entre le taux de change et sa valeur fondamentale croît avec γ . Une exception est notée lorsque γ prend une valeur de 20. Cette première mesure d'instabilité est en moyenne plus faible pour notre extension que pour le modèle de référence. Néanmoins, cette différence n'est significative que lorsque γ vaut 0, 1, 2 ou 5.

Les deux modèles semblent incapables de générer des périodes d'instabilité pour γ égal à 0, 1 ou 2 (voir Annexe 8.2.10). Dans l'ensemble, le nombre moyen de périodes d'instabilité semble augmenter avec γ . Nous observons néanmoins une exception pour le modèle de référence : le nombre moyen pour γ égal à 20 est proche, mais inférieur à celui observé lorsque γ vaut 10. Notre extension génère en moyenne moins de périodes d'instabilité que le modèle de référence. Cependant, ces différences ne sont, à nouveau, pas significatives lorsque γ vaut 10 ou 20. Des résultats relativement similaires sont obtenus pour les nombres moyens de périodes de bulle et de périodes de krach (voir Annexes 8.2.11 et 8.2.12)¹¹.

Les nombres moyens de bulles et de krachs augmentent avec γ (voir Annexes 8.2.13 et 8.2.14). Notre extension génère significativement moins de bulles et de krachs que le modèle de référence

10. Lorsque γ est égal à 0, les agents ne changent pas d'heuristique, en conséquence la proportion d'agents utilisant une heuristique spécifique est fixe et égale à 50 % (poids de chaque heuristique au temps 0).

11. Bien que certaines différences soient significatives à un seuil de significativité de 10 %.

lorsque γ vaut 5, 10 ou 20.

Pour toutes les valeurs de γ testées permettant de générer des périodes d'instabilité (5, 10 et 20), les durées moyennes des bulles et des krachs sont significativement plus importantes pour notre extension (voir Annexes 8.2.15 et 8.2.16). Les durées moyennes des bulles et des krachs augmentent avec γ dans un premier temps. Dans un second temps, elles diminuent lorsque la valeur du paramètre augmente.

En conclusion, les capacités du modèle de référence et de notre extension à générer des périodes d'instabilité et à se remettre de ces dernières semblent très dépendantes de γ . Dans cette perspective, nos résultats sont sensibles à la propension des agents à réviser leur règle de prédiction. Néanmoins, bien que certains résultats ne soient pas significatifs, les tendances observées pour les différentes valeurs de γ permettant de générer des bulles et des krachs semblent corroborer les résultats obtenus précédemment : le remplacement des agents chartistes par des agents machine learner permet en moyenne de stabiliser les marchés.

Nombre de retards considérés

Nous nous intéressons ensuite à la sensibilité de nos résultats au nombre de retards considérés par les agents machine learner lors de l'apprentissage de leur règle de prédiction. Dans la configuration initiale de l'extension, ils considèrent quatre retards. Nous testons les nombres de retards suivants : 1, 2, 3, 4, 5 et 6.

Nos résultats ne semblent pas impactés par le nombre de retards considérés par les agents machine learner. En effet, pour toutes les valeurs testées, les nombres moyens de périodes d'instabilité, de bulles et de krachs générés par notre extension sont significativement inférieurs à ceux produits par le modèle de référence. Les fréquences moyennes des bulles et des krachs sont également significativement plus faibles pour notre extension. De plus, les durées moyennes des bulles et des krachs sont significativement plus importantes pour notre extension. L'ensemble de ces résultats est disponible dans la sous-section 8.3.3 des annexes.

Par contre, la stabilité des marchés semble, en règle générale, se dégrader lorsque les agents considèrent plus de retards. Par exemple, la valeur moyenne des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale augmente avec le nombre de retards considérés (à l'exception du passage de 1 à 2 retards). Les nombres moyens de périodes d'instabilité et de périodes de bulle augmentent également avec le nombre de retards considérés. Le nombre de périodes de krach reste relativement stable pour toutes les valeurs testées. Le nombre moyen de bulles augmente lors du passage d'un retard à deux retards et reste relativement stable pour les autres nombres de retards considérés. Une tendance relativement similaire est observée pour le nombre moyen de krachs.

Cette augmentation de l'instabilité est probablement due aux ensembles plus importants de va-

riables considérés lors de l’entraînement de la règle de prédiction des agents chartistes machine learner. Bien que LASSO cherche à sélectionner les prédicteurs les plus pertinents parmi ces ensembles, le nombre limité d’observations utilisées pour l’entraînement et la validation de l’heuristique peut mener à la sélection de variables n’étant pas les plus pertinentes. De plus, la règle de prédiction estimée impacte le taux de change après le remplacement des agents chartistes. Ce remplacement peut mener à des dynamiques du taux de change très différentes de celles utilisées pour l’entraînement et la validation de la règle. Ainsi, en augmentant le nombre de variables considérées durant l’entraînement et la validation, on augmente la probabilité d’obtenir une nouvelle règle chartiste très différente de la règle initiale. Certaines de ces nouvelles règles pourraient augmenter l’instabilité observée sur les marchés en diminuant, par exemple, la capacité du modèle à mettre fin à une période d’instabilité ou en augmentant la probabilité de krachs ou de bulles.

Algorithme utilisé

Dans ce mémoire, nous avons fait l’hypothèse que les agents machine learner utilisaient LASSO pour lutter contre les problèmes de sous-apprentissage et de surapprentissage. Bien que ce choix soit particulièrement attrayant d’un point de vue théorique et relativement adapté aux hypothèses des modèles à agents hétérogènes, il est à tout à fait possible que de meilleurs résultats soient obtenus avec d’autres outils d’apprentissage automatique. Ainsi, nous souhaitons évaluer la sensibilité de nos résultats au type d’algorithme utilisé par les agents chartistes machine learner. Toutefois, pour rester cohérent avec l’utilisation d’heuristiques par les agents, nous ne considérons que des méthodes simples : la méthode des moindres carrés ordinaire (MCO), Ridge et Elastic Net. De brèves explications concernant Ridge et Elastic Net sont fournies ci-dessous.

Ridge est une technique de régularisation relativement similaire à LASSO. En effet, seule la pénalisation est légèrement différente. Ridge pénalise la somme des coefficients au carré alors que LASSO pénalise la somme des valeurs absolues des coefficients. Les coefficients obtenus avec Ridge minimisent la fonction objectif suivante :

$$\text{Fonction objectif} = \sum_{i=1}^n (y_i - \sum_j x_{ij} \cdot \alpha_j)^2 + \lambda \cdot \sum_{j=1}^P \alpha_j^2 \quad (31)$$

où y_i est la variable dépendante, λ la constante de régularisation, P le nombre de variables indépendantes et $\sum_j x_{ij} \cdot \alpha_j$ la prédiction faite par le modèle.

Contrairement à LASSO, Ridge pousse certains coefficients vers 0, mais ne les force pas à être exactement égaux à 0. Comme pour LASSO, la valeur de la constante de pénalisation λ est déterminée à l’aide d’une validation croisée à k blocs spécifiquement adaptée aux séries temporelles.

Elastic Net est également une technique de régularisation. Elle combine les pénalités de LASSO

et de Ridge. En effet, les coefficients estimés à l'aide d'Elastic Net minimisent la fonction objectif suivante :

$$\text{Fonction objectif} = \sum_{i=1}^n (y_i - \sum_j x_{ij} \cdot \alpha_j)^2 + \lambda \cdot \sum_{j=1}^P [(1 - \theta) \cdot \alpha_j^2 + \theta \cdot |\alpha_j|] \quad (32)$$

où y_i est la variable dépendante, λ la constante de régularisation, P le nombre de variables indépendantes et $\sum_j x_{ij} \cdot \alpha_j$ la prédiction faite par le modèle. θ est compris entre 0 et 1 et détermine les proportions de pénalité de type LASSO et de type Ridge. Les valeurs de θ et λ sont obtenues via une validation croisée spécifiquement adaptée aux séries temporelles.

Nous comparons les résultats moyens obtenus pour les différents types d'algorithmes (LASSO, MCO, Ridge et Elastic Net) et pour le modèle de référence à l'aide d'analyses de variance univariées (One-way ANOVAs). Une analyse de variance est un test statistique permettant de comparer les moyennes de trois groupes ou plus. Son hypothèse nulle est que tous les groupes possèdent la même moyenne. Lorsque cette hypothèse est rejetée, cela indique qu'au moins un groupe possède une moyenne significativement différente des autres. Cependant, le test n'indique pas quel(s) groupe(s). C'est pourquoi nous utilisons un test de Tukey lorsque l'hypothèse nulle de l'analyse de variance est rejetée. Ce test post hoc permet de déterminer quel(s) groupe(s) possède(nt) une moyenne significativement différente des autres.

L'analyse de variance possède plusieurs hypothèses : les différents groupes doivent être indépendants, leur distribution normale et leur variance homogène. Lorsqu'au moins une de ces hypothèses n'est pas respectée, nous utilisons le test de Kruskal-Wallis, un test non paramétrique considéré comme une alternative à l'ANOVA. Lorsqu'au moins un des groupes est significativement différent des autres (p-value du test de Kruskal-Wallis inférieure ou égale à 0,05), nous employons le test de Dunn. Ce test est une alternative non paramétrique au test post hoc de Tukey. Il permet de déterminer quels groupes sont significativement différents des autres.

Nous ne constatons aucune différence significative au niveau des résultats produits par LASSO, Ridge, MCO et Elastic Net (voir sous-section 8.2.4 des annexes). En effet, les moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale, les nombres de périodes d'instabilité, de périodes de bulle et de périodes de krach, les fréquences et les durées des bulles et des krachs ne sont pas en moyenne significativement différentes pour ces algorithmes. En revanche, les valeurs moyennes des différentes mesures d'instabilité calculées pour le modèle de référence sont significativement différentes de celles des autres groupes. Nos résultats ne semblent donc pas sensibles au type d'algorithme employé par les agents machine learner¹².

12. À noter que seuls des algorithmes cohérents avec l'utilisation d'heuristiques ont été testés.

L'absence de différence significative entre les différentes techniques de régularisation et la méthode des moindres carrés ordinaire pourrait être expliquée par plusieurs raisons. D'une part, les agents pourraient avoir accès à suffisamment d'informations pour ne pas faire face à un problème de surapprentissage. En effet, le jeu de données d'entraînement pourrait être suffisant pour apprendre correctement les vraies relations entre les différentes variables indépendantes considérées et la variable dépendante. La plus-value apportée par les techniques de régulation serait négligeable ou inexistante. Cette plus-value pourrait devenir significative en réduisant la taille de l'ensemble d'entraînement et/ou en augmentant la complexité de la règle à estimer (par exemple, en considérant un nombre de retards et/ou un degré de la forme polynomiale plus importants). D'autre part, le remplacement de l'heuristique chartiste par une heuristique plus sophistiquée influence les dynamiques du taux de change. De ce fait, la performance des algorithmes de pénalisation pourrait être meilleure que celle de la méthode des moindres carrés ordinaire sur des dynamiques similaires à celles observées avant le remplacement des agents chartistes. Néanmoins, cette performance accrue pourrait ne pas être observée en raison de l'influence de la nouvelle heuristique sur les dynamiques du taux de change.

4.2. Ajout des agents chartistes machine learner

4.2.1. Pertinence du modèle

Clusters de volatilité

L'ajout de l'heuristique chartiste machine learner dans l'ensemble restreint de règles de prédiction pouvant être sélectionnées par les agents ne semble pas influencer la capacité du modèle à générer des clusters de volatilité. En effet, l'hypothèse nulle du test ARCH de Engle est rejetée pour toutes les simulations. Cela indique l'existence de clusters de volatilité dans les rendements de chaque série simulée à l'aide de notre extension. La distinction entre les périodes de haute volatilité et de basse volatilité est, cependant, moins flagrante pour notre extension (voir figure 4.2.1). De plus, la variance moyenne des rendements est significativement plus faible pour notre extension (voir table 4.2.1).

Queues de distribution épaisses

Nous effectuons, dans un premier temps, un test de Jarque-Bera. Les résultats de ces tests nous indiquent que 77 simulations sur 100 ne suivent pas une loi normale. Nous nous intéressons, ensuite, de manière plus spécifique à la présence de queues de distribution épaisses pour les rendements de nos différentes simulations. Pour ce faire, nous testons pour chaque simulation si le kurtosis des rendements est significativement supérieur à 3 (test unilatéral à droite). Nos résultats indiquent la présence de queues de distribution épaisses pour 84 simulations. De manière similaire au modèle

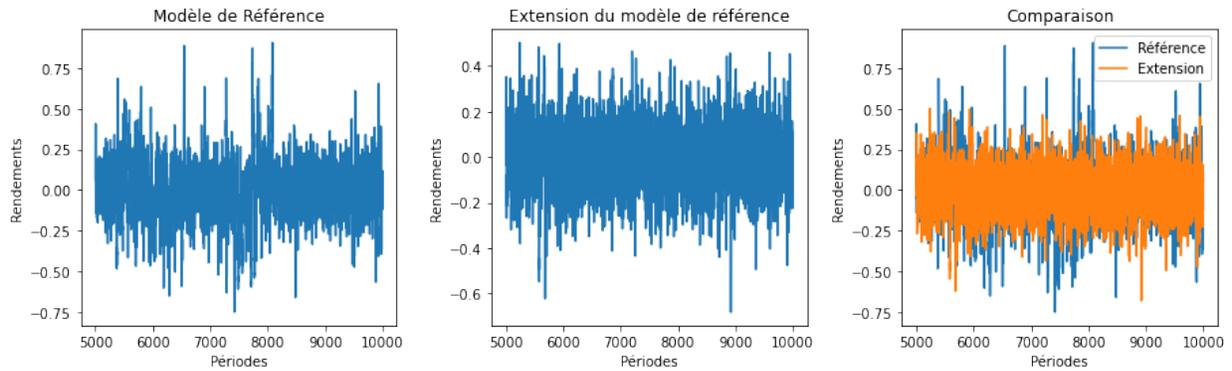


Figure 4.2.1 – Évolution et comparaison des rendements de nos différents modèles après l’ajout de la règle chartiste machine learner. La simulation sélectionnée est représentative des résultats généraux.

	Minimum	Maximum	Moyenne	Variance	Skewness	Excès de Kurtosis
Moyenne - Référence	-0.86	0.86	0	0.04	0.01	1.22
Moyenne - Extension	-0.61	0.61	-0	0.02	-0	0.32
Levene p-value	0.1	0.24	0	0	0	0
Shapiro-Wilk p-value	0	0.67	0	0	0.02	0
Test	Wilcoxon	Student	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0.2	0	0.5	0

Table 4.2.1 – Comparaison de statistiques descriptives des rendements générés par les deux modèles. Nous utilisons des tests unilatéraux. L’hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l’extension.

de référence (queues de distribution épaisses pour 87 simulations sur 100), notre extension semble capable de générer le plus souvent des rendements possédant des queues de distributions épaisses.

Excès de volatilité

Pour rappel, nous évaluons la présence d'excès de volatilité à l'aide du « noise to signal ratio ». Un ratio supérieur à 1 indique la présence d'excès de volatilité. Notre extension semble incapable de générer ce fait stylisé pour la plupart des simulations (seules 33 simulations sur 100 possèdent un ratio supérieur à 1).

Le ratio moyen obtenu pour les différentes simulations de notre extension vaut 15,16 (voir table 4.2.2). Le ratio moyen du modèle de référence est significativement supérieur à ce dernier et est égal à 85,05. En somme, ce résultat signifie que la proportion de la volatilité du taux de change liée à la volatilité de sa valeur fondamentale est en moyenne significativement plus importante pour notre extension (pour rappel, une augmentation de cette proportion induit une diminution de la valeur du « noise to signal ratio »).

	Noise to signal ratio
Moyenne - Référence	85.05
Moyenne - Extension	15.16
Levene p-value	0
Shapiro-Wilk p-value	0
Test	Wilcoxon
Test p-value	0

Table 4.2.2 – Comparaison des valeurs moyennes du « Noise to signal ratio ». Nous utilisons un test unilatéral. L'hypothèse nulle de ce test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

Déconnexion du taux de change

Notre modèle n'est pas capable de répliquer ce fait stylisé pour la majorité de nos simulations. En effet, l'hypothèse nulle du test de cointégration de Engle-Granger est rejetée pour 58 simulations sur 100. Il existe donc une cointégration significative entre le taux de change et sa valeur fondamentale pour ces simulations. Par conséquent, nous ne répliquons pas le « disconnect puzzle » pour ces dernières. En comparaison, notre modèle de référence reproduit le plus souvent ce fait stylisé (60 simulations sur 100), mais est incapable de le répliquer de manière systématique.

Conclusion sur la pertinence de l'extension

Bien que cette extension permette de reproduire tous les faits stylisés d'intérêt, elle est incapable de le faire de manière systématique pour la plupart de ces régularités empiriques. Pour les valeurs des paramètres considérées, nous constatons une plus grande facilité à répliquer les faits stylisés

d'intérêt de la part de notre modèle de référence. En ce sens, ce dernier est plus pertinent que notre extension.

De nouveau, ces résultats peuvent sembler décevants à première vue. Cependant, ils sont, en réalité, très intéressants pour répondre à notre question de recherche : quel est l'impact des agents machine learner sur la stabilité des marchés de change. En effet, en possédant une capacité de réplication des faits empiriques d'intérêt plus faible que notre modèle de référence, l'extension semble indiquer que la présence d'agents chartistes machine learner permet d'améliorer l'efficacité des marchés et, par conséquent, leur stabilité. De plus, l'extension reste pertinente puisqu'elle permet de générer les faits stylisés d'intérêt.

4.2.2. Impact des agents machine learner sur la stabilité des marchés

Dans cette sous-section, nous évaluons de manière plus rigoureuse l'impact sur la stabilité de l'ajout d'agents chartistes machine learner. Comme pour la première extension, nous procédons d'abord à une analyse graphique. Nous comparons ensuite les valeurs moyennes de différentes mesures d'instabilité calculées pour notre modèle de référence et notre extension.

La plupart des simulations produites par notre extension présentent des dynamiques similaires à celles présentées par la figure 4.2.2. Sur cette figure, nous pouvons voir que le taux de change oscille autour de sa valeur fondamentale et reste relativement proche de cette dernière durant toute la simulation. Bien que les dynamiques observées pour le modèle de référence sont le plus souvent proches de celles produites par notre extension, il leur arrive fréquemment de s'éloigner fortement de la valeur fondamentale du taux de change. En ce sens, l'ajout d'agents chartistes machine learner semble stabiliser les marchés de change.

Néanmoins, nous n'observons pas cette tendance pour toutes les simulations réalisées. D'une part, pour certaines simulations générées par notre extension, le taux de change demeure relativement éloigné de sa valeur fondamentale pour une durée très importante (parfois pour toute la durée de la simulation, voir figures 4.2.3 et 4.2.4). Les simulations pour lesquelles nous observons ce phénomène sont les simulations dans lesquelles l'ajout de la nouvelle heuristique a été réalisé durant une période d'instabilité (i.e., au moment de l'ajout, le taux de change était très éloigné de sa valeur fondamentale). Nous avons également constaté ce phénomène pour notre première extension. D'autre part, dans certaines simulations, notre seconde extension génère et se remet de périodes de bulle et de krach alors que l'ajout de la nouvelle heuristique a été effectué durant une période de stabilité (voir figure 4.2.5).

En résumé, l'introduction d'agents chartistes machine learner conscients des problèmes de sous-apprentissage et de surapprentissage dans un marché de change initialement composé d'agents

fondamentalistes et d'agents chartistes peu sophistiqués semble le plus souvent stabiliser ce marché. Néanmoins, cette introduction n'empêche pas l'apparition de bulles ou de krachs et peut même allonger la durée de ces périodes d'instabilité.

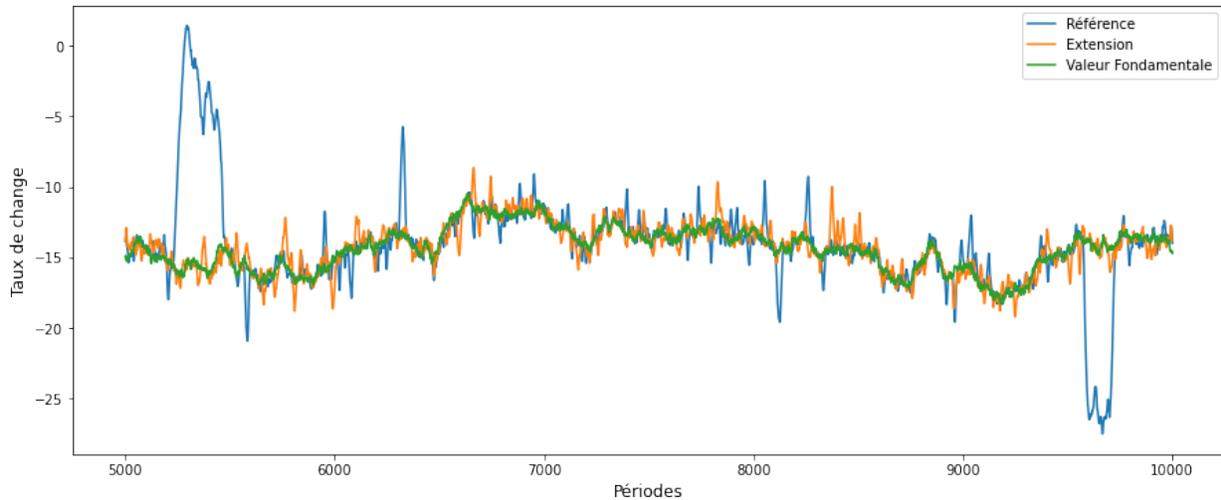


Figure 4.2.2 – Comparaison des dynamiques du taux de change générées par le modèle de référence et par l'extension (ajout des agents chartistes machine learner).

Comme le montrent les figures 4.2.3, 4.2.4 et 4.2.5, le marché est composé (quasiment) exclusivement d'agents chartistes (chartistes peu sophistiqués et chartistes machine learner) durant les périodes d'instabilité. Lors des périodes de stabilité, les agents fondamentalistes sont présents sur le marché. Nous observons, au cours de ces périodes, des variations importantes au niveau des proportions d'agents adoptant une heuristique particulière. Nous avons constaté la même chose pour notre modèle de référence et notre première extension. Les dynamiques menant à la formation de bulles ou de krachs semblent donc similaires pour les trois modèles et correspondent aux explications fournies par De Grauwe and Grimaldi (voir sous-section 4.1.2).

Nous comparons, maintenant, les dynamiques générées par notre seconde extension et par le modèle de référence à l'aide de plusieurs mesures cherchant à quantifier l'instabilité des marchés simulés. Nous procédons à des tests de comparaison de moyennes unilatéraux pour ces mesures. Nous fixons le seuil de significativité à 5 % pour ces tests.

Comme nous pouvons le supposer au vu de notre analyse graphique, l'introduction d'agents chartistes conscients des problèmes de sous-apprentissage et de surapprentissage et traitant ces problèmes avec des techniques d'apprentissage automatique permet en moyenne de réduire la variance du taux de change (p-value du test unilatéral égale à 0, voir table 4.2.3). En effet, la variance du taux de change est en moyenne significativement plus faible pour notre extension que pour le modèle de référence.

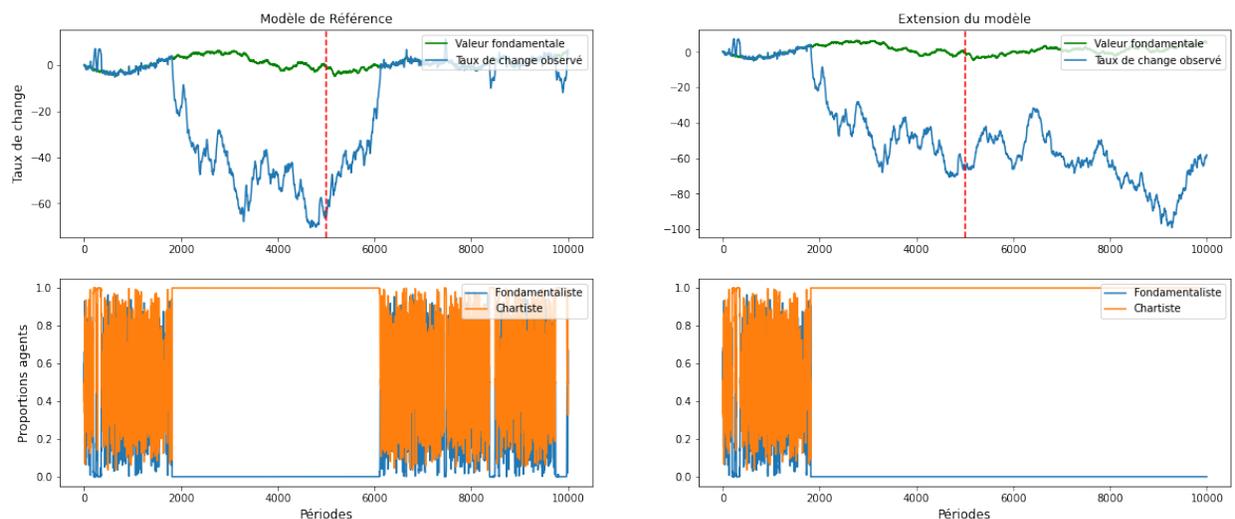


Figure 4.2.3 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (ajout des agents chartistes machine learner) et le modèle de référence - Exemple de période d’instabilité prolongée sans retour à l’équilibre suite à l’ajout des agents. La ligne verticale rouge correspond à la période durant laquelle la nouvelle heuristique est introduite.

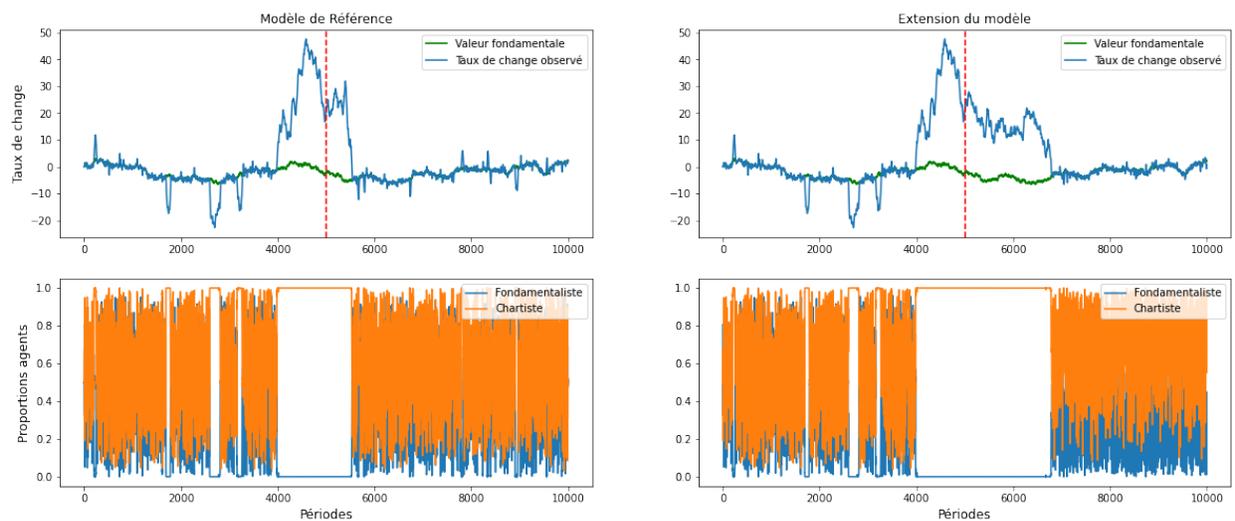


Figure 4.2.4 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (ajout des agents chartistes machine learner) et le modèle de référence - Exemple de période d’instabilité prolongée avec retour à l’équilibre suite à l’ajout des agents. La ligne verticale rouge correspond à la période durant laquelle la nouvelle heuristique est introduite.

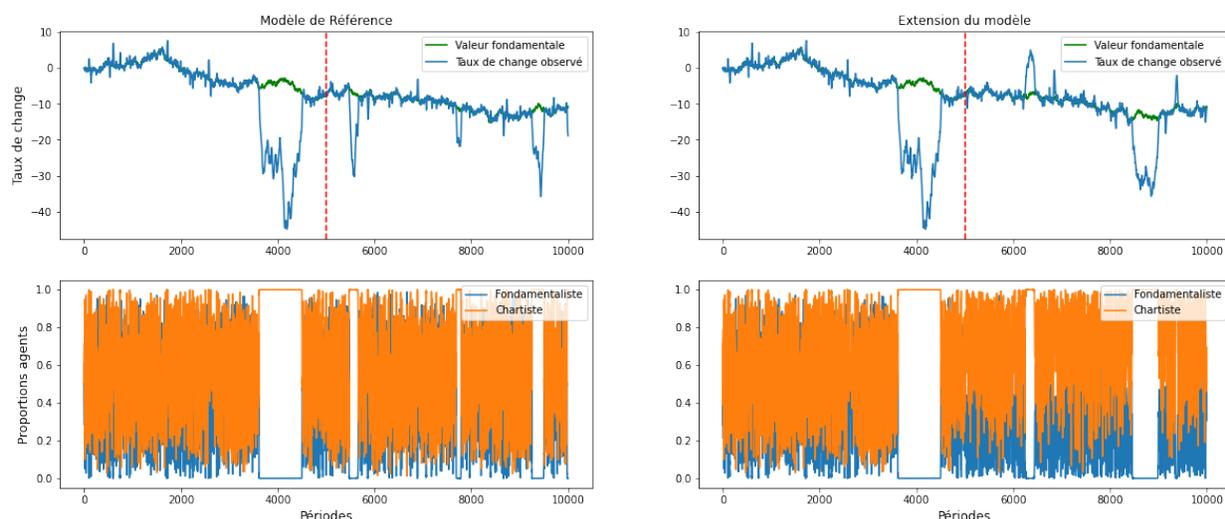


Figure 4.2.5 – Comparaison des dynamiques du taux de change et de la composition du marché pour l’extension (ajout des agents chartistes machine learner) et le modèle de référence - Exemple de périodes de stabilité et d’instabilité générées suite à l’ajout des agents. La ligne verticale rouge correspond à la période durant laquelle la nouvelle heuristique est introduite.

	Minimum	Maximum	Moyenne	Variance
Moyenne - Référence	-33.22	30.14	-1.51	374.66
Moyenne - Extension	-20.17	6.91	-6.77	72.36
Levene p-value	0.09	0.01	0.48	0
Shapiro-Wilk p-value	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0.88	0

Table 4.2.3 – Comparaison des minimums, maximums, moyennes et variances moyens observés pour le modèle de référence et l’extension (ajout des agents chartistes machine learner). Nous utilisons des tests unilatéraux. L’hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l’extension.

La valeur moyenne de notre première mesure d'instabilité (la moyenne quadratique des écarts entre le taux de change et sa valeur fondamentale) est significativement plus faible pour notre extension que pour le modèle de référence (p-value du test égale à 0, voir table 4.2.4). Ainsi, cette mesure montre également l'impact positif de la nouvelle heuristique sur la stabilité des marchés.

	Moyenne quadratique des écarts
Moyenne - Référence	24.27
Moyenne - Extension	14.93
Levene p-value	0.16
Shapiro-Wilk p-value	0
Test	Wilcoxon
Test p-value	0

Table 4.2.4 – Comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale. Nous utilisons un test unilatéral. L'hypothèse nulle de ce test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

Nous observons une réduction significative des nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach suite à l'introduction de la nouvelle heuristique (les p-values des tests unilatéraux sont inférieures à 0,05 pour les trois mesures, voir table 4.2.5). Le nombre de périodes de krach semble beaucoup plus important que le nombre de périodes de bulle pour notre extension. Cela est probablement dû au caractère aléatoire de nos simulations et au temps significatif nécessaire au taux de change pour revenir à l'équilibre lorsque la nouvelle heuristique est introduite durant une période d'instabilité¹³.

	Périodes d'instabilité	Périodes de bulle	Périodes de krach
Moyenne - Référence	1584.1	707.66	876.44
Moyenne - Extension	1178.78	371.37	807.41
Levene p-value	0.52	0.06	0.79
Shapiro-Wilk p-value	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0

Table 4.2.5 – Comparaison des nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

Sur base de notre analyse graphique, nous nous attendions à une réduction des nombres moyens de bulles et de krachs ainsi qu'à une augmentation de leur durée moyenne. Ces attentes sont en partie confirmées par nos tests unilatéraux. En effet, notre extension génère significativement moins de bulles et de krachs en moyenne (p-values égales à 0, voir table 4.2.6). Les krachs sont également significativement plus longs pour notre extension que pour le modèle de référence (la p-value du

13. La nouvelle règle est plus souvent introduite durant un krach que pendant une bulle.

test vaut 0, voir table 4.2.7). Cependant, la durée moyenne des bulles n'est pas significativement plus importante pour notre extension (p-value égale à 0,31, voir table 4.2.7). De nouveau, cette différence de résultats entre les bulles et les krachs est probablement due au caractère stochastique de nos simulations et au temps significatif nécessaire au taux de change pour revenir à l'équilibre lorsque la nouvelle heuristique est introduite durant une période d'instabilité.

	Nombre de bulles	Nombre de krachs
Moyenne - Référence	1.04	1.18
Moyenne - Extension	0.28	0.29
Levene p-value	0	0
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0	0

Table 4.2.6 – Comparaison des nombres moyens de bulles et de krachs après l'introduction de la nouvelle heuristique. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Durée des bulles	Durée des krachs
Moyenne - Référence	973.6	974.85
Moyenne - Extension	1498.41	3228.15
Levene p-value	0.18	0.02
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0.31	0

Table 4.2.7 – Comparaison des durées moyennes des bulles et des krachs après l'introduction de la nouvelle heuristique. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

En conclusion, l'introduction d'agents chartistes machine learner dans un marché de change composé d'agents chartistes très primaires et d'agents fondamentalistes semble le plus souvent améliorer la stabilité et l'efficacité du marché. Cependant, bien que la présence des agents machine learner réduise en moyenne les fréquences des bulles et des krachs, elle n'empêche pas la formation de ces périodes d'instabilité. De plus, l'introduction des nouveaux agents allonge en moyenne les durées des bulles et des krachs¹⁴, en particulier lorsque cette introduction a lieu durant une période d'instabilité.

14. Néanmoins, ce résultat n'est pas significatif pour les bulles.

4.2.3. Analyse de sensibilité

Dans cette sous-section, nous analysons la sensibilité de nos résultats à certains paramètres des modèles. Nous nous concentrons sur l'influence des paramètres suivants : le degré d'extrapolation des agents chartistes, la sensibilité des agents à la rentabilité des heuristiques (vitesse à laquelle les agents changent d'heuristique pour en adopter une plus profitable), le nombre de retards considérés par les agents machine learner et l'algorithme utilisé par ces derniers.

Degré d'extrapolation des agents chartistes

Pour rappel, le degré d'extrapolation des agents chartistes est défini par le paramètre β de notre extension. Nous nous attendons à ce que les marchés soient plus instables lorsque la valeur de β augmente (i.e., lorsque le degré d'extrapolation des agents chartistes augmente). Nous confirmons cette hypothèse en étudiant les résultats obtenus pour les valeurs suivantes de β : 0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 0,8 et 0,9.

Pour toute valeur de β inférieure ou égale à 0,7, la moyenne des écarts quadratiques entre le taux de change et sa valeur fondamentale n'est pas en moyenne significativement inférieure pour notre extension (voir Annexe 8.3.1). Néanmoins, elle l'est pour un degré d'extrapolation égal à 0,8 ou 0,9. Les valeurs moyennes de cette première mesure d'instabilité augmentent avec β . Cet accroissement n'est pas linéaire, mais est de plus en plus important à mesure que β augmente. Ces résultats confirment l'influence du degré d'extrapolation des agents chartistes sur les dynamiques générées par notre extension et le modèle de référence. En effet, le taux de change est en moyenne plus proche de sa valeur fondamentale pour un degré d'extrapolation plus faible.

L'influence du degré d'extrapolation des agents chartistes sur les résultats obtenus est confirmée par nos autres mesures d'instabilité. Les résultats produits par les configurations initiales des modèles (i.e., lorsque β vaut 0,9) ne sont pas similaires aux résultats obtenus pour les autres valeurs testées. En effet, les deux modèles ne semblent pas capables de générer des périodes d'instabilité (bulles ou krachs) pour un β inférieur ou égal à 0,7 (voir Annexe 8.3.2). De plus, les nombres moyens de périodes de bulle et de périodes de krach générés par notre extension ne sont pas significativement inférieurs à ceux du modèle de référence lorsque β vaut 0,8 (voir Annexes 8.3.3 et 8.3.4). Des résultats similaires sont obtenus pour les nombres moyens de bulles et de krachs (voir Annexes 8.3.5 et 8.3.6). La durée moyenne des krachs générés par notre extension n'est pas non plus significativement supérieure pour ce degré d'extrapolation. À noter que nous ne pouvons pas comparer les durées moyennes des bulles pour β égal à 0,8, car notre extension n'a produit aucune bulle pour cette valeur de β (voir Annexes 8.3.7 et 8.3.8).

En conclusion, le degré d'extrapolation des agents chartistes influence fortement la capacité des deux modèles à générer des bulles et des krachs. Cette capacité étant cruciale pour nos résultats,

ceux-ci sont fortement influencés par la valeur du paramètre β .

Sensibilité des agents à la profitabilité des heuristiques

Le paramètre γ mesure l'intensité avec laquelle les agents révisent leur règle de prédiction. Plus la valeur de ce paramètre est élevée, plus les agents ont tendance à changer rapidement d'heuristique. Nous testons six valeurs pour le paramètre γ : 0, 1, 2, 5, 10 et 20.

Les modèles ne sont pas capables de générer des bulles et des krachs pour γ égal à 0, 1 et 2 (voir Annexes 8.3.13 et 8.3.14). En conséquence, nous nous concentrons sur les résultats obtenus pour les autres valeurs de γ testées (5, 10 et 20). Pour ces valeurs, notre extension produit en moyenne moins de bulles et de krachs que le modèle de référence. Néanmoins, la réduction du nombre de bulles n'est pas significative pour γ égal à 10. Les nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach produits par notre extension ne sont pas significativement inférieurs lorsque γ vaut 10 ou 20. De plus, les durées moyennes des bulles et des krachs générés par notre extension ne sont pas significativement supérieures pour ces valeurs. En somme, nos résultats semblent très dépendants de la valeur de γ .

Étudions à présent l'influence de γ sur la stabilité des marchés simulés par nos deux modèles. Dans l'ensemble, les marchés semblent moins stables lorsque les traders révisent plus rapidement leur règle de prédiction. En effet, les nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach sont généralement plus élevés lorsque γ augmente (voir Annexes 8.3.10, 8.3.11 et 8.3.12). Une tendance similaire est observée pour les nombres moyens de bulles et de krachs et pour les valeurs moyennes des moyennes quadratiques entre le taux de change et sa valeur fondamentale (voir Annexes 8.3.13, 8.3.14 et 8.3.9). En revanche, nous n'observons pas une tendance linéaire pour les durées moyennes des bulles et des krachs. En effet, elles augmentent avec γ dans un premier temps et diminuent à partir d'une certaine valeur de γ lorsque ce dernier augmente (voir Annexes 8.3.15 et 8.3.16). Une explication plausible à ces résultats est la suivante : lorsque γ est suffisamment faible, les agents fondamentalistes peuvent difficilement être expulsés du marché par les agents chartistes. Le marché demeure alors à l'équilibre pour l'ensemble de la simulation. Lorsque la valeur de γ augmente, la capacité des agents chartistes à expulser les agents fondamentalistes s'accroît. Des bulles et des krachs peuvent ainsi se former. Lorsque la vitesse à laquelle les agents adoptent une nouvelle heuristique est suffisamment importante, les périodes d'instabilité se forment et disparaissent très facilement et rapidement. Il en résulte une augmentation du nombre de bulles et de krachs ainsi qu'une diminution de leur durée.

Nombre de retards considérés

Nous évaluons ensuite la sensibilité de nos résultats au nombre de retards considérés par les agents chartistes machine learner lors de l'apprentissage de leur règle de prédiction. Nous testons les

nombres de retards suivants : 1, 2, 3, 4, 5 et 6. Pour rappel, le nombre de retards dans la configuration initiale de l'extension était égal à 4.

Nos résultats ne semblent pas être impactés par le nombre de retards considérés par les agents machine learner. Pour toutes les valeurs testées, l'introduction de l'heuristique chartiste basée sur des méthodes d'apprentissage automatique permet en moyenne de stabiliser les marchés. En effet, les moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale sont en moyenne significativement plus faibles pour notre extension que pour le modèle de référence (voir Annexe 8.3.17). De plus, les nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach sont significativement inférieurs pour notre extension (voir Annexes 8.3.18, 8.3.19 et 8.3.20). Les fréquences moyennes des bulles et des krachs sont également réduites par l'ajout de l'heuristique (voir Annexes 8.3.21 et 8.3.22). Enfin, les durées moyennes des krachs et des bulles sont plus élevées pour notre extension (voir Annexes 8.3.23 et 8.3.24). Cependant, pour la plupart des valeurs testées, ce résultat n'est pas significatif pour la durée moyenne des bulles.

Le nombre de retards considérés par les agents semble avoir une influence sur la stabilité des marchés simulés par notre extension. Cependant, aucune tendance claire ne se dégage. En effet, lorsque nous comparons les valeurs des mesures d'instabilité pour les différents nombres de retards considérés, nous constatons que l'augmentation du nombre de retards peut mener à une augmentation de la stabilité ou à une diminution de la stabilité.

Nous pensons que ce résultat est principalement dû à deux raisons. D'une part, en augmentant le nombre de retards, LASSO doit sélectionner les prédicteurs les plus pertinents dans un ensemble bien plus important de variables indépendantes. A priori, un ensemble plus important possède une plus grande probabilité de contenir les prédicteurs les plus pertinents. Ainsi, augmenter le nombre de retards permettrait d'améliorer la stabilité des marchés. D'autre part, au vu du nombre limité de données disponibles pour l'entraînement et la validation du modèle, LASSO pourrait identifier de manière erronée certains prédicteurs comme étant les plus pertinents. Ainsi, augmenter le nombre de retards considérés par les agents machine learner n'améliore pas nécessairement la stabilité des marchés de change simulés.

Algorithme utilisé

Comme pour notre première extension, nous nous intéressons à l'influence du type d'algorithme utilisé par les agents chartistes machine learner sur nos résultats. Nous considérons trois alternatives à LASSO : la méthode des moindres carrés ordinaire (MCO), Ridge et Elastic Net.

Nous comparons les différents résultats en effectuant des analyses de variance univariée (One-way ANOVA) et en employant des tests post hoc de Tukey si au moins un groupe est en moyenne significativement différent des autres. Lorsque les hypothèses sous-jacentes de l'ANOVA ne sont

pas respectées, nous effectuons des tests de Kruskal-Wallis et des tests post hoc de Dunn si au moins un groupe est en moyenne significativement différent des autres.

Nous n’observons aucune différence significative au niveau des résultats des différents algorithmes considérés (LASSO, MCO, Ridge et Elastic Net). En effet, les moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale, les nombres de périodes d’instabilité, de périodes de bulle et de périodes de krach, les fréquences et les durées des bulles et des krachs ne sont pas en moyenne significativement différents pour ces quatre algorithmes. Ces résultats sont disponibles dans la sous-section 8.3.4 des annexes.

Comme indiqué précédemment, l’absence de différence significative entre les différentes techniques de régularisation et la méthode des moindres carrés ordinaire pourrait être due à plusieurs facteurs. D’une part, la plus-value des techniques de régulation pourrait être négligeable ou inexistante, car les agents disposent de suffisamment des données pour apprendre les vraies relations entre les différentes variables indépendantes considérées et la variable dépendante. D’autre part, la nouvelle heuristique influence les dynamiques du taux de change après son introduction. En conséquence, les techniques de pénalisation pourraient produire de meilleurs résultats pour des dynamiques similaires à celles sur lesquelles elles ont été entraînées. Cependant, nous n’observons pas cette performance accrue en raison de l’influence de la nouvelle heuristique sur les dynamiques du taux de change.

Les valeurs moyennes des différentes mesures d’instabilité du modèle de référence sont significativement différentes de celles des autres groupes. Nos résultats ne semblent donc pas sensibles au type d’algorithme utilisé par les agents machine learner¹⁵.

4.3. Comparaison des deux extensions

Dans cette sous-section, nous comparons la pertinence de nos extensions et leurs résultats. Nous considérons uniquement les configurations initiales des modèles (i.e., les valeurs des paramètres de deux modèles sont celles indiquées dans la table 3.3.1).

Pour rappel, notre première extension suppose le remplacement de l’heuristique chartiste par une règle de décision chartiste plus sophistiquée à un moment t . Cette hypothèse est très forte puisqu’elle implique que tous les agents chartistes adoptent des méthodes d’apprentissage automatique au même moment. Cela signifie également que l’ancienne heuristique chartiste ne peut plus être employée par les agents à partir de cet instant t . Cette extension permet d’isoler l’impact d’agents chartistes machine learner sur la stabilité des marchés de change. Ainsi, notre modèle pourrait notamment fournir une indication concernant les conséquences d’une nouvelle législation visant

15. À noter que seuls des algorithmes cohérents avec l’utilisation d’heuristiques par les agents ont été testés.

à limiter les risques associés aux problèmes de sous-apprentissage et de surapprentissage. Cette extension pourrait également permettre d'étudier quand cette nouvelle législation devrait être introduite (au vu de nos résultats pour cette extension, durant une période de stabilité).

Malgré l'intérêt de notre première extension, nous considérons que notre seconde extension est plus réaliste d'un point de vue théorique. Celle-ci introduit l'heuristique chartiste estimée via LASSO à un moment t . Les agents peuvent continuer de sélectionner l'heuristique chartiste initiale après l'introduction de la nouvelle règle de prédiction. Par conséquent, tous les agents chartistes du modèle n'utilisent pas des techniques d'apprentissage automatique. L'adoption de la nouvelle heuristique chartiste se fait de manière progressive si l'heuristique permet aux agents de générer un plus grand profit. Cette extension permet d'étudier l'impact sur la stabilité d'agents chartistes machine learner lorsque ceux-ci cohabitent avec des agents chartistes n'utilisant pas des méthodes d'apprentissage automatique.

Comparons la pertinence de nos deux modèles afin de déterminer quelle est l'extension la plus réaliste en pratique. Bien que nos extensions permettent de reproduire les quatre faits stylisés considérés dans ce mémoire (clusters de volatilité, queues de distribution épaisses, excès de volatilité, déconnexion du taux de change de sa valeur fondamentale), elles ne sont pas capables de tous les répliquer de manière systématique. En outre, nos deux modèles génèrent des clusters de volatilité pour l'ensemble de leurs simulations. Comparativement à la première extension, la seconde extension produit plus fréquemment des queues de distribution épaisses (84 simulations sur 100 contre 44 sur 100 pour notre première extension) et de l'excès de volatilité (« noise to signal ratio » supérieur à 1 pour 33 simulations contre 24 pour notre première extension). Le nombre de simulations pour lesquelles on observe la déconnexion du taux de change de sa valeur fondamentale est relativement similaire pour les deux modèles (42 pour notre seconde extension et 45 pour notre première extension). Ces résultats confirment nos attentes théoriques : l'ajout d'une nouvelle heuristique chartiste basée sur des méthodes d'apprentissage automatique (seconde extension) semble générer des dynamiques de taux de change plus proches de la réalité que le remplacement de l'heuristique chartiste initialement définie (première extension).

Nous nous intéressons à présent aux résultats concernant la stabilité des marchés simulés. Les deux modèles indiquent que la présence d'agents chartistes machine learner stabilise en moyenne les marchés de change, mais allonge la durée des périodes d'instabilité. En effet, leur présence permet en moyenne de réduire les fréquences des bulles et des krachs, le nombre de périodes d'instabilité et la moyenne quadratique des écarts entre le taux de change et sa valeur fondamentale. Cependant, les agents machine learner prolongent en moyenne les périodes d'instabilité. Bien que les deux modèles produisent des résultats similaires, il est intéressant d'analyser les dynamiques générées par ces derniers afin de déterminer si elles présentent des différences significatives. Au vu de nos analyses

dans les sous-sections précédentes, nous attendons à une plus grande instabilité pour notre seconde extension ainsi qu'à des périodes de bulle et de krach moins longues. En effet, la cohabitation entre agents chartistes machine learner et non machine learner semble augmenter la capacité des modèles à générer et à se remettre de périodes d'instabilité.

Nos attentes sont partiellement confirmées par les tests de comparaison de moyennes¹⁶. En effet, bien que nos différentes mesures indiquent en moyenne une plus grande instabilité pour notre seconde extension, seule la moyenne quadratique des écarts entre le taux de change et sa valeur fondamentale est en moyenne significativement supérieure pour notre seconde extension. En revanche, les durées moyennes des bulles et des krachs générés par notre première extension sont significativement plus importantes. Les résultats des différents tests de comparaison de moyennes sont disponibles dans la sous-section 8.4 des annexes.

16. Comme précédemment, nous avons procédé à des tests unilatéraux. Les hypothèses de ces tests sont spécifiées dans les annotations associées aux tableaux de résultats.

5. Discussion

Dans cette section, nous résumons nos résultats, les comparons à la littérature existante, évoquons les limites de cette étude et suggérons quelques développements et pistes d'amélioration.

5.1. Résumé des résultats

Au travers de ce mémoire, nous nous sommes intéressé à l'impact des agents chartistes machine learner sur la stabilité des marchés de change. Nous avons plus précisément étudié l'impact d'agents chartistes conscients des problèmes de sous-apprentissage et de surapprentissage et traitant ces derniers à l'aide de LASSO. Afin d'isoler et d'évaluer cet impact, nous avons créé deux extensions à un modèle « à la De Grauwe et Grimaldi », un modèle à agents hétérogènes permettant de simuler des dynamiques de taux de change proches de la réalité. Notre première extension suppose l'adoption de techniques d'apprentissage automatique par tous les agents chartistes à un temps t . Dans cette extension, les agents chartistes du modèle de référence sont donc remplacés par des agents machine learner. Notre seconde extension ne repose pas sur une hypothèse aussi forte. Dans ce modèle, les agents ont accès à une nouvelle heuristique basée sur des techniques d'apprentissage automatique, mais peuvent toujours employer l'heuristique chartiste initialement définie. De notre point de vue, cette représentation des marchés est plus réaliste que le modèle de référence et que la première extension. En effet, elle permet la coexistence d'agents chartistes adoptant une heuristique relativement simple et d'agents chartistes utilisant une règle de prédiction plus sophistiquée reposant sur des outils d'apprentissage automatique.

Nous avons démontré la pertinence des trois modèles en prouvant que ceux-ci sont capables de reproduire différents faits stylisés observés sur les marchés de change (clusters de volatilité, queues de distribution épaisses, excès de volatilité et déconnexion du taux de change de sa valeur fondamentale).

Les résultats de nos deux extensions ont montré que la présence d'agents chartistes machine learner permet en moyenne de stabiliser les marchés de change en réduisant, entre autres, la variance du taux de change, la distance entre le taux de change et sa valeur fondamentale, le nombre de périodes d'instabilité et les fréquences des bulles et des krachs. Néanmoins, les durées moyennes des bulles et des krachs sont sensiblement prolongées suite à la présence de ces agents. L'allongement des durées moyennes des bulles et des krachs est dû à la difficulté des extensions à revenir à l'équilibre lorsque le remplacement des agents chartistes ou l'ajout des agents machine learner se produit durant une période d'instabilité.

Les marchés générés par notre seconde extension affichent en moyenne une plus grande instabilité

que ceux créés à partir de la première extension¹⁷. Ainsi, bien que la présence d'agents chartistes machine learner stabilise en moyenne les marchés, la présence conjointe de ces agents et d'agents chartistes n'adoptant pas d'outil d'apprentissage automatique semble réduire leur influence positive sur la stabilité des marchés. Cependant, les durées moyennes des bulles et des krachs sont significativement plus courtes pour la seconde extension. La présence d'agents chartistes non machine learner sur les marchés semble donc favoriser la création de périodes d'instabilité et accélérer le retour du taux de change à l'équilibre.

Nous avons également procédé à une analyse de sensibilité de nos résultats en nous focalisant sur certains paramètres. Les résultats énoncés ci-dessus sont influencés par les valeurs du paramètre d'extrapolation des agents chartistes et par la vitesse à laquelle les agents adoptent une nouvelle heuristique. Nos résultats ne semblent, cependant, pas sensibles au nombre de retards considérés par les agents machine learner ou au type d'algorithme employé par ces derniers¹⁸.

5.2. Parallèles avec la littérature

Nos résultats sont cohérents avec ceux que Georges and Pereira (2021) ont obtenus au moyen d'un modèle à agents hétérogènes composé uniquement d'agents chartistes. En effet, Georges and Pereira ont montré que l'utilisation de méthodes de régularisation par les agents chartistes permet d'améliorer la stabilité des marchés, mais n'empêche pas la formation de périodes d'instabilité. De plus, nos conclusions corroborent les résultats de plusieurs articles dédiés à l'influence du trading algorithmique sur la stabilité des marchés¹⁹. Par exemple, Chaboud et al. (2014) ont démontré que la présence accrue de trading algorithmique n'est pas associée à une plus grande volatilité du taux de change. Les auteurs ont suggéré que le trading algorithmique permettrait de réduire la volatilité du taux de change. D'autres chercheurs (tels que Aggarwal and Thomas (2014); Brogaard, Hendershott, and Riordan (2014); Hendershott, Jones, and Menkveld (2011); Nawn and Banerjee (2019)) ont également indiqué que le trading algorithmique améliorerait l'efficacité des marchés en favorisant le processus de découverte des prix (« price discovery process »), en augmentant la liquidité des marchés et en réduisant leur volatilité.

5.3. Limites et pistes d'amélioration

Comme tout travail scientifique, notre mémoire n'est pas exempt de limites. La principale est inhérente à la nature de nos données. En effet, nous raisonnons sur base de simulations générées à partir

17. Toutefois, cette différence n'est pas significative pour la plupart de nos mesures d'instabilité.

18. Nous n'avons testé que des algorithmes cohérents avec l'utilisation d'heuristiques par les agents.

19. Comme indiqué dans l'introduction de ce mémoire, les agents machine learner présents dans nos extensions peuvent être considérés comme des agents chartistes relativement sophistiqués ou des traders algorithmiques.

de modèles relativement simples. De plus, ces modèles ne sont pas calibrés sur des données réelles et leurs prédictions ne sont pas confrontées aux réalisations observées sur les marchés. Bien que la performance des modèles puisse se dégrader au cours du temps, nos agents machine learner ne réentraînent pas le modèle dictant leur règle de prédiction une fois que ce dernier a été estimé, ce qui constitue une deuxième limite importante. Il est, en effet, peu probable que des agents conscients des problèmes de sous-apprentissage et de surapprentissage ne réentraînent pas leur modèle sur une fenêtre de 5000 observations²⁰. Néanmoins, cette limite peut être expliquée par la puissance de calcul nécessaire afin d'effectuer un ou plusieurs réentraînements de la règle de prédiction. Une troisième limite est l'hypothèse supposant que la valeur fondamentale du taux de change est connue par les agents fondamentalistes. Bien que cette hypothèse soit courante dans les modèles à agents hétérogènes, cette dernière reste extrêmement forte. Enfin, nous ne procédons pas à une analyse de sensibilité exhaustive. En effet, le nombre de paramètres dans nos modèles étant conséquent, nous n'avons pas eu l'occasion d'évaluer la sensibilité de nos résultats à chacun d'entre eux²¹.

La recherche est, la plupart du temps, un processus incrémental. Les chercheurs se basent sur les travaux d'autres scientifiques, cherchent à les confirmer et à les améliorer en proposant de nouvelles idées, en adoptant une autre méthodologie, etc. Pour faciliter la tâche des chercheurs intéressés par notre travail, nous proposons ci-dessous plusieurs développements et pistes d'amélioration. Il serait, par exemple, intéressant d'incorporer d'autres heuristiques dans les modèles telles que des heuristiques chartistes basées sur d'autres méthodes d'apprentissage automatique ou une heuristique fondamentaliste reposant sur ce type de méthodes. Un autre développement pourrait être l'ajout des coûts de transaction dans les modèles. Il serait également pertinent de confirmer nos résultats à l'aide d'autres mesures d'instabilité et/ou d'autres modèles à agents hétérogènes. Enfin, toute modification permettant de gommer les limites présentées ci-dessus constituerait une piste d'amélioration judicieuse.

Au-delà de ce mémoire, nous pensons qu'il est crucial de continuer à développer des modèles multi-agents²². Ces modèles permettent aux chercheurs d'expérimenter et d'évaluer des théories relatives aux mécaniques et interactions à l'origine des dynamiques observées sur les marchés. Ces modèles présentent également un immense potentiel pour les législateurs. D'une part, ils peuvent être mis à profit afin d'estimer et d'anticiper les conséquences d'une nouvelle législation ou ligne de conduite. En effet, selon Mizuta (2016), il est difficile d'envisager ces changements en se limitant aux résultats d'études empiriques, car, ce faisant, il est laborieux d'isoler leur impact. De plus, ces

20. Cependant, selon la fréquence d'observation considérée (secondes, minutes, heures, jours...), il est tout à fait possible que des agents machine learner ne réévaluent pas la performance de leur modèle durant 5000 périodes.

21. Il aurait notamment été intéressant d'évaluer l'influence du nombre d'observations utilisées pour l'entraînement de la règle de prédiction des agents machine learner.

22. Pour rappel, les modèles à agents hétérogènes sont un type particulier de modèles multi-agents.

études ne considèrent que des situations s'étant déjà produites. D'autre part, les modèles multi-agents pourraient être utilisés afin de valider les règles de décision et les algorithmes employés par les agents présents sur les marchés. Par exemple, les législateurs pourraient obliger les traders à entraîner leurs algorithmes sur des données simulées par un modèle multi-agents et à ensuite introduire la règle de prédiction estimée dans le modèle afin d'évaluer son impact sur la stabilité des marchés. Enfin, les modèles multi-agents sont particulièrement intéressants pour les traders puisqu'ils leur permettent de générer facilement des périodes d'instabilité et des grandes quantités de données afin d'entraîner et de valider leurs algorithmes.

6. Conclusion

Dans ce mémoire, nous nous sommes intéressés à l'influence des agents chartistes machine learner sur la stabilité des marchés de change. Nous avons mesuré leur impact en comparant les dynamiques générées par trois modèles à agents hétérogènes : un modèle de référence permettant de répliquer certaines régularités empiriques des marchés de change et deux extensions de ce modèle. Les dynamiques produites par les trois modèles émergent des interactions et des croyances de leurs agents. Ces dernières sont définies par un ensemble restreint d'heuristiques. Au début de chaque période, les agents prédisent l'évolution du taux de change sur base d'une de ces heuristiques. L'évolution réelle du taux de change dépend des attentes des agents et d'un bruit blanc gaussien. Après chaque période, les agents évaluent la performance de la règle de prédiction qu'ils ont adoptée à la période précédente et adaptent au besoin leur stratégie. Dans le modèle de référence, les agents peuvent sélectionner deux heuristiques : une heuristique chartiste relativement basique et une heuristique fondamentaliste. Notre première extension considère le remplacement de l'heuristique chartiste par une règle chartiste plus complexe (une forme polynomiale autorégressive) estimée à l'aide de LASSO, un outil d'apprentissage automatique permettant de lutter contre le problème de surapprentissage. Cette nouvelle heuristique ne remplace pas la règle de prédiction chartiste dans la seconde extension, mais est ajoutée à l'ensemble des heuristiques pouvant être employées par les agents.

Nos résultats indiquent que la présence d'agents chartistes machine learner permet en moyenne de stabiliser les marchés de change. En effet, le taux de change semble moins dévier de sa valeur fondamentale, les fréquences des bulles et des krachs sont réduites et, globalement, le nombre de périodes d'instabilité est plus faible pour nos deux extensions que pour le modèle de référence. Néanmoins, les durées moyennes des bulles et des krachs des extensions sont supérieures à celles du modèle de référence. En cas de période d'instabilité, la présence des agents machine learner semble donc ralentir le retour du taux de change à l'équilibre. Nos résultats sont dépendants de la valeur du paramètre d'extrapolation des agents chartistes et de la vitesse à laquelle les agents changent d'heuristique. En revanche, ils ne semblent pas sensibles au type d'algorithme employé par les agents machine learner et au nombre de retards pris en compte par ces agents. Nos conclusions sont cohérentes avec les résultats de Georges and Pereira (2021), des auteurs ayant également cherché à mesurer l'influence des agents machine learner sur la stabilité des marchés via un modèle à agents hétérogènes. De plus, nos résultats corroborent ceux de différentes études s'intéressant à l'impact du trading algorithmique sur la qualité et l'efficacité des marchés²³.

23. Les agents machine learner de nos extensions peuvent être considérés comme des traders algorithmiques.

Au terme de ce mémoire, nous sommes persuadé que l'emploi de modèles multi-agents par les traders et les législateurs pourrait favoriser la stabilité des marchés. D'une part, les modèles multi-agents sont capables de générer facilement des données réalistes permettant notamment aux traders de créer des modèles plus robustes aux périodes d'instabilité. D'autre part, les législateurs peuvent employer ce type de modèles pour évaluer les répercussions de nouvelles règles ou lignes de conduite. Nous espérons que ce mémoire motivera d'autres chercheurs à incorporer des agents machine learner dans leurs modèles multi-agents afin de créer des modèles toujours plus réalistes et, ainsi, motiver l'utilisation de ces derniers par les législateurs et les agents financiers.

7. Bibliographie

- Aggarwal, N., and Thomas, S. (2014). The causal impact of algorithmic trading on market quality..
- Akçay, E., and Hirshleifer, D. (2021, June). Social finance as cultural evolution, transmission bias, and market dynamics. *Proceedings of the National Academy of Sciences*, 118(26), 2015568118-.
- Allen, H., and Taylor, M. P. (1990). Charts, noise and fundamentals in the london foreign exchange market. *The Economic Journal*, 100(400), 49–59.
- Anufriev, M., Bao, T., and Tuinstra, J. (2016). Microfoundations for switching behavior in heterogeneous agent models : An experiment. *Journal of Economic Behavior & Organization*, 129, 74-99.
- Barberis, N., and Thaler, R. (2002, 10). A survey of behavioral finance. *Advances in Behavioral Finance*, 2.
- Baxter, M., and Stockman, A. C. (1989, May). Business cycles and the exchange-rate regime : Some international evidence. *Journal of Monetary Economics*, 23(3), 377-400.
- Bonabeau, E. (2002). Agent-based modeling : Methods and techniques for simulating human systems. *Proceedings of the national academy of sciences*, 99(suppl_3), 7280–7287.
- Bracke, P., Datta, A., Jung, C., and Sen, S. (2019, août). Machine learning explainability in finance : an application to default risk analysis [Bank of England working papers]. (816).
- Brock, W., and Hommes, C. (1997, 02). A rational route to randomness. *Econometrica*, 65, 1059-1096.
- Brogaard, J., Hendershott, T., and Riordan, R. (2014, 06). High-Frequency Trading and Price Discovery. *The Review of Financial Studies*, 27(8), 2267-2306.
- Burrell, J. (2016, 01). How the machine 'thinks' : Understanding opacity in machine learning algorithms. *Big Data & Society*, 3.
- Béreau, S. (2013). Time is money : An heterogeneous agent model for the fx. In *Springer proceedings in complexity*. Springer.
- Chaboud, A., Chiquoine, B., Hjalmarsson, E., and Vega, C. (2014). Rise of the machines : Algorithmic trading in the foreign exchange market. *The Journal of Finance*, 69(5), 2045-2084.
- Chen, Y., and Hao, Y. (2017). A feature weighted support vector machine and k-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355.
- Cheung, Y.-W., Chinn, M. D., and Marsh, I. W. (2004). How do UK-based foreign exchange dealers think their market operates? *International Journal of Finance & Economics*, 9(4), 289-306.
- Consoli, S., Reforgiato Recupero, D., and Saisana, M. (2021). *Data science for economics and finance : Methodologies and applications*.

- Cont, R. (2002, 03). Empirical properties of asset returns : Stylized facts and statistical issues. *Quantitative Finance*, 1, 223-236.
- De Grauwe, P., and Grimaldi, M. (2002, 02). The exchange rate and its fundamentals. a chaotic perspective. *SSRN Electronic Journal*.
- De Grauwe, P., and Grimaldi, M. (2005a, 09). Bubbles and crashes in a behavioural finance model. *SSRN Electronic Journal*.
- De Grauwe, P., and Grimaldi, M. (2005b). Heterogeneity of agents, transactions costs and the exchange rate. *Journal of Economic Dynamics and Control*, 29(4), 691-719. (Bounded rationality, heterogeneity and market dynamics)
- De Grauwe, P., and Grimaldi, M. (2006). Exchange rate puzzles : A tale of switching attractors. *European Economic Review*, 50(1), 1-33.
- De Grauwe, P., and Grimaldi, M. (2018). *The exchange rate in a behavioral finance framework*. Princeton University Press.
- De Grauwe, P., and Rovira Kaltwasser, P. (2006, 02). A behavioral finance model of the exchange rate with many forecasting rules. *SSRN Electronic Journal*.
- De Long, J. B., Shleifer, A., Summers, L. H., and Waldmann, R. J. (1990). Noise trader risk in financial markets. *Journal of Political Economy*, 98(4), 703-738.
- de Vries, C. G. (2001). Fat tails and the history of the guilders..
- Dieci, R., and He, X.-Z. (2018). Chapter 5 - heterogeneous agent models in finance. In C. Hommes and B. LeBaron (Eds.), *Handbook of computational economics* (Vol. 4, p. 257-328). Elsevier.
- Faust, J., Rogers, J. H., Swanson, E., and Wright, J. H. (2003). Identifying the effects of monetary policy shocks on exchange rates using high frequency data. *Journal of the European Economic Association*, 1(5), 1031–1057.
- Flood, R. P., and Rose, A. K. (1995). Fixing exchange rates a virtual quest for fundamentals. *Journal of Monetary Economics*, 36(1), 3-37.
- Frankel, J., and Froot, K. (1987). Using survey data to test standard propositions regarding exchange rate expectations. *American Economic Review*, 77(1), 133-53.
- Frankel, J., and Froot, K. (1990). Chartists, fundamentalists, and trading in the foreign exchange market. *American Economic Review*, 80(2), 181-85.
- Gaunersdorfer, A., and Hommes, C. (2007). A nonlinear structural model for volatility clustering. In *Long memory in economics* (pp. 265–288). Springer.
- Georges, C. (2008). Bounded memory, overparameterized forecast rules, and instability. *Economics Letters*, 98(2), 129-135.
- Georges, C., and Pereira, J. (2021). Market stability with machine learning agents. *Journal of Economic Dynamics and Control*, 122, 104032.
- Goodell, J., Kumar, S., Lim, W. M., and Pattnaik, D. (2021, 08). Artificial intelligence and machine

- learning in finance : Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32.
- Goodhart, C. (1989). News and the foreign exchange market [FMG Discussion Papers].
- Goodhart, C., and Figliuoli, L. (1991). Every minute counts in financial markets. *Journal of International Money and Finance*, 10(1), 23-52.
- Gu, S., Kelly, B., and Xiu, D. (2020, 02). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hansen, K. B. (2020). The virtue of simplicity : On machine learning models in algorithmic trading. *Big Data & Society*, 7(1), 2053951720926558.
- Hastie, T., Tibshirani, R., and Friedman, J. H. (2009). *The elements of statistical learning : data mining, inference, and prediction* (Vol. 2). Springer.
- Hastie, T., Tibshirani, R., and Wainwright, M. (2015). Statistical learning with sparsity. *Monographs on statistics and applied probability*, 143, 143.
- He, X.-Z., and Li, Y. (2007, 03). Power-law behaviour , heterogeneity, and trend chasing. *Journal of Economic Dynamics and Control*, 31, 3396-3426.
- He, X.-Z., and Li, Y. (2008, 02). Heterogeneity, convergence, and autocorrelations. *Quantitative Finance*, 8, 59-79.
- Heemeijer, P., Hommes, C., Sonnemans, J., and Tuinstra, J. (2009). Price stability and volatility in markets with positive and negative expectations feedback : An experimental investigation. *Journal of Economic Dynamics and Control*, 33(5), 1052-1072.
- Hendershott, T., Jones, C. M., and Menkveld, A. J. (2011). Does algorithmic trading improve liquidity? *The Journal of Finance*, 66(1), 1-33.
- Hommes, C. (2006). Chapter 23 heterogeneous agent models in economics and finance. In L. Tesfatsion and K. Judd (Eds.), (Vol. 2, p. 1109-1186). Elsevier.
- Hommes, C., Sonnemans, J., Tuinstra, J., and van de Velden, H. (2005). Coordination of expectations in asset pricing experiments. *The Review of Financial Studies*, 18(3), 955–980.
- Kahneman, D., Knetsch, J. L., and Thaler, R. H. (1991, March). Anomalies : The endowment effect, loss aversion, and status quo bias. *Journal of Economic Perspectives*, 5(1), 193-206.
- Kaizoji, T. (2003, 01). Speculative bubbles and fat-tail phenomena in a heterogeneous agent model. *arXiv.org, Quantitative Finance Papers*.
- Kapoor, S., and Prosad, J. M. (2017). Behavioural finance : A review. *Procedia computer science*, 122, 50–54.
- Kavajecz, K. A., and Odders-White, E. R. (2004, 01). Technical Analysis and Liquidity Provision. *The Review of Financial Studies*, 17(4), 1043-1071.
- Kaya, O., and Schildbach, J. (2016). High-frequency trading. *Reaching the limits, Automated trader magazine*, 41, 23–27.

- Kirilenko, A. A., and Lo, A. W. (2013, May). Moore's law versus murphy's law : Algorithmic trading and its discontents. *Journal of Economic Perspectives*, 27(2), 51-72.
- Koedijk, K. G., Stork, P. A., and de Vries, C. G. (1992, October). Differences between foreign exchange rate regimes : The view from the tails. *Journal of International Money and Finance*, 11(5), 462-473.
- Lee, C. M. C., Shleifer, A., and Thaler, R. H. (1991). Investor sentiment and the closed-end fund puzzle. *The Journal of Finance*, 46(1), 75-109.
- Lux, T., and Alfarano, S. (2016). Financial power laws : Empirical evidence, models, and mechanisms. *Chaos, Solitons & Fractals*, 88, 3-18. (Complexity in Quantitative Finance and Economics)
- Lux, T., and Marchesi, M. (1998, 08). Volatility clustering in financial markets : A microsimulation of interacting agents. *International Journal of Theoretical and Applied Finance*, 3.
- Lux, T., and Zwickels, R. (2018). Empirical validation of agent-based models. In C. Hommes and B. LeBaron (Eds.), *Handbook of computational economics* (Vol. 4, pp. 437–488). Elsevier.
- Mailagaha Kumbure, M., Lohrmann, C., Luukka, P., and Porras, J. (2022, 02). Machine learning techniques and data for stock market forecasting : A literature review. *Expert Systems with Applications*, 197, 116659.
- Mandelbrot, B. (1963). The variation of certain speculative prices. *The Journal of Business*, 36.
- Manzan, S. (2009). Finance, agent based modeling in. In R. A. Meyers (Ed.), *Encyclopedia of complexity and systems science* (pp. 3374–3388). Springer.
- Menkhoff, L. (1998). The noise trading approach — questionnaire evidence from foreign exchange. *Journal of International Money and Finance*, 17(3), 547-564.
- Menkhoff, L. (2010). The use of technical analysis by fund managers : International evidence. *Journal of Banking & Finance*, 34(11), 2573-2586.
- Menkhoff, L., and Taylor, M. P. (2007). The obstinate passion of foreign exchange professionals : Technical analysis. *Journal of Economic Literature*, 45(4), 936–972.
- Mill, J. S. (1874). *Essays on some unsettled questions of political economy*. John W. Parker.
- Mizuta, T. (2016). A brief review of recent artificial market simulation (agent-based model) studies for financial market regulations and/or rules. *Regulation of Financial Institutions eJournal*.
- Nawn, S., and Banerjee, A. (2019). Do the limit orders of proprietary and agency algorithmic traders discover or obscure security prices? *Journal of Empirical Finance*, 53, 109-125.
- Obstfeld, M., and Rogoff, K. (2000). The six major puzzles in international macroeconomics : Is there a common cause? *NBER Macroeconomics Annual*, 15, 339–390.
- OECD. (2021). *Artificial Intelligence, Machine Learning and Big Data in Finance Opportunities, Challenges and Implications for Policy Makers* (Rapport technique). Organisation de coopération et de développement économiques.

- Palm, F., Huisman, R., Koedijk, C., and Kool, C. (2002, 1^{er} janvier). The tail fatness of fx returns reconsidered. *De Economist*, 150(3), 299–312.
- Raman, N., and Leidner, J. L. (2019, 06). Financial market data simulation using deep intelligence agents. In (p. 200-211).
- Ramiah, V., Xu, X., and Moosa, I. A. (2015). Neoclassical finance, behavioral finance and noise traders : A review and assessment of the literature. *International Review of Financial Analysis*, 41, 89-100.
- Ryll, L., Barton, M., Zhang, B., McWaters, J., Schizas, E., Hao, R., ... Yerolemou, N. (2020, 02). Transforming paradigms : A global ai in financial services survey. *SSRN Electronic Journal*.
- Ryll, L., and Seidens, S. (2019). Evaluating the performance of machine learning algorithms in financial market forecasting : A comprehensive survey. *arXiv preprint arXiv :1906.07786*.
- Sargent, T. J. (1993). *Bounded Rationality in Macroeconomics : The Arne Ryde Memorial Lectures* (N° 9780198288695). Oxford University Press.
- Shefrin, H. (2008). *A behavioral approach to asset pricing*. Elsevier.
- Simon, H. A. (1957). Models of man ; social and rational.
- Singh, J. E., Babshetti, V., and Shivaprasad, H. (2021). Efficient market hypothesis to behavioral finance : A review of rationality to irrationality. *Materials Today : Proceedings*.
- Taylor, M., and Allen, H. (1992). The use of technical analysis in the foreign exchange market. *Journal of International Money and Finance*, 11(3), 304-314.
- Tversky, A., and Kahneman, D. (1974). Judgment under uncertainty : Heuristics and biases. *Science*, 185(4157), 1124–1131.
- Williamson, J. (1985). The exchange rate system : John williamson, study no. 4, institute for international economics, washington, dc (mit press, cambridge, ma, 1983) pp. 85. *Journal of Banking & Finance*, 9(2), 333-333.
- Zhao, D., and Li, K. (2022). Bounded rationality, adaptive behaviour, and asset prices. *International Review of Financial Analysis*, 80, 102037.

8. Annexes

8.1. Codes

8.1.1. Code - Modèle de référence

```
# Importation des librairies

import scipy
from scipy import stats

import random

import numpy as np

import math

import matplotlib.pyplot as plt

import pandas as pd

import warnings
warnings.filterwarnings('ignore')

import json

# Choix des Paramètres

n1 = 10000 # Nombre d'observations par simulation
n2 = 100 # Nombre de simulations ---> nombre de colonnes des matrices "Output"
n3 = 5000 # Nombre d'observations pour l'entraînement des modèles

psi = 0.2 # le coefficient de la règle fondamentaliste (% de mauvais alignement attendu
↳ à être corrigé)
beta = 0.9 # Le coefficient de la règle chartiste (paramètre d'extrapolation)
gamma = 5 # Mesure l'intensité avec laquelle les agents révisent leurs règles de
↳ prédiction

r = 0 # taux d'intérêt domestique
r_star = 0 # taux d'intérêt étranger
mu = 0.5 # aversion pour le risque dans l'expression du profit ajusté

# Définition des vecteurs (vecteurs nuls de taille (n,1))
```

```

# Ces vecteurs sont utilisés pour les simulations avec deux types d'agents : agents
↳ chartistes et agents fondamentalistes

s = [0 for x in range((n1 + 1))] # la taille de s est n1+1 car on définit la boucle
↳ s_t+1 en fonction de s_t

s_star = [0 for x in range(n1)]

w_c = [0 for x in range (n1)]
w_f = [0 for x in range(n1)]

E_f = [0 for x in range(n1)]
E_c = [0 for x in range(n1)]

pi_f = [0 for x in range(n1)]
pi_c = [0 for x in range(n1)]

sigma2_f = [0 for x in range(n1)]
sigma2_c = [0 for x in range(n1)]

pi_prime_f = [0 for x in range(n1)]
pi_prime_c = [0 for x in range(n1)]

# Définition des matrices "output"
# 1er argument = #lignes, #2ème = #colonnes
S = np.zeros((n1 + 1, n2))
S_star = np.zeros((n1, n2))
W_f = np.zeros((n1, n2))
W_c = np.zeros((n1, n2))
E_f_matrix = np.zeros((n1, n2))
E_c_matrix = np.zeros((n1, n2))

# Initialisation des premières valeurs des vecteurs
for i in [s, s_star, E_f, E_c, pi_f, pi_c, sigma2_f, sigma2_c, pi_prime_f, pi_prime_c]:
    i[0] = 0

# Poids des agents au temps t = 0 => autant de chartistes que de fondamentalistes
for i in [w_f, w_c]:
    i[0] = 0.5

# Boucle pour j = 1 à n2 - réplification de la simulation n2 fois

# Fixation du seed pour retomber sur les mêmes résultats
np.random.seed(440)

```

```

# Boucle for pour générer les données pour chaque simulation
for j in range(n2):
    print(f"itération {j+1} sur {n2}")

    # Initialisation de la première valeur de la série de taux de change observé
    s[1] = s[0] + np.random.normal(0, 0.1, 1)

    # Boucle pour générer les données (t = 0 à n1)
    for i in range(1, n1):

        # Evaluation de la valeur fondamentale du taux de change (supposé suivre une
        ↪ Random Walk sans dérive)
        s_star[i] = s_star[i-1] + np.random.normal(0, 0.1, 1)

        # Evaluation des anticipations de taux de change pour chaque type d'agent (F et
        ↪ C):
        E_f[i] = (1 - psi)*s[i] + psi * s_star[i]
        E_c[i] = (1 + beta)*s[i] - beta*s[i-1]
        # Avec E[i] = anticipation au temps i+1

        # Valeurs des profits non-ajustés selon les deux règles (F et C) :
        pi_f[i] =
        ↪ (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+r_star)*E_f[i-1]-(1+r)*s[i-1])
        pi_c[i] =
        ↪ (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+r_star)*E_c[i-1]-(1+r)*s[i-1])

        # Remarque : np.sign renvoie 1 si valeur positive, -1 si valeur négative et 0 si
        ↪ valeur nulle

        # Valeurs des variances associées aux erreurs de prévision selon les deux règles
        ↪ (mesure du risque) :
        sigma2_f[i] = (E_f[i-1]-s[i])**2
        sigma2_c[i] = (E_c[i-1]-s[i])**2

        # Valeurs des profits ajustés :
        pi_prime_f[i] = pi_f[i] - mu*sigma2_f[i]
        pi_prime_c[i] = pi_c[i] - mu*sigma2_c[i]

        # Evaluation des poids de chaque type d'agents
        w_f[i] = (math.exp(gamma*pi_prime_f[i]))/(math.exp(gamma*pi_prime_f[i]) +
        ↪ math.exp(gamma*pi_prime_c[i]))
        w_c[i] = (math.exp(gamma*pi_prime_c[i]))/(math.exp(gamma*pi_prime_f[i]) +
        ↪ math.exp(gamma*pi_prime_c[i]))

```

```

# Evaluation du taux de change en t+1 connu comme la somme pondérée par les
↳ poids de
# chaque type d'agents, de leurs anticipations du taux de change + bruit
↳ gaussien
s[i+1] = s[i]-w_f[i]*psi*(s[i]-s_star[i])+w_c[i]*beta*(s[i]-s[i-1]) +
↳ np.random.normal(0, 0.1, 1)

# Remplace la colonne j des matrices par les données correspondantes générées pour
↳ la simulation
S[:,j] = s
S_star[:,j] = s_star
W_f[:,j] = w_f
W_c[:,j] = w_c
E_c_matrix[:,j] = E_c
E_f_matrix[:,j] = E_f

# Elimine la (n+1)ème composante de s
S = np.delete(S, n1, 0)

# Création d'un dictionnaire avec les données importantes
results_dict = {}

for n in range(n2):

    results = {}

    results['S'] = S[:,n].tolist()
    results['S_star'] = S_star[:, n].tolist()
    results['E_f'] = E_f_matrix[:, n].tolist()
    results['E_c'] = E_c_matrix[:, n].tolist()
    results['W_f'] = W_f[:, n].tolist()
    results['W_c'] = W_c[:, n].tolist()

    results_dict[f'Sim_{n+1}'] = results

# Sauvegarde dans un fichier json (évite de recalculer à chaque fois les séries)
with open(f'DG_référence_{beta}_{gamma}_{mu}.json', 'w') as outfile:
    json.dump(results_dict, outfile)

```

8.1.2. Code - Remplacement des agents chartistes

```
# Importation des librairies

import scipy
from scipy.ndimage.interpolation import shift

import random

import numpy as np
from numpy import arange

import math

import matplotlib.pyplot as plt

import pandas as pd

from sklearn.linear_model import LinearRegression, Lasso, Ridge, ElasticNet
from sklearn.preprocessing import RobustScaler, PolynomialFeatures, StandardScaler,
↳ MinMaxScaler
from sklearn.model_selection import GridSearchCV, train_test_split, TimeSeriesSplit
from sklearn.pipeline import Pipeline

import json
from time import sleep
from tqdm import tqdm

import warnings
warnings.filterwarnings('ignore')

# Chargement des données du modèle de référence
with open('DG_référence_0.9_5_0.5.json') as json_file:
    data = json.load(json_file)

# Paramètres

n1 = len(data['Sim_1']['S']) # Nombre d'observations par simulation
n2 = len(data) # Nombre de simulations
n3 = 5000 # Période à laquelle la nouvelle règle est introduite

number_lags = 4 # Nombre de retards (variation du taux de change) pris en compte dans la
↳ règle ML
degree_poly = 3 # degré du polynome
```

```

psi = 0.2 # le coefficient de la règle fondamentaliste (% de mauvais alignement attendu
↳ à être corrigé)
beta = 0.9 # Le coefficient de la règle chartiste (paramètre d'extrapolation)
gamma = 5 # Mesure l'intensité avec laquelle les agents révisent leurs règles de
↳ prédiction

r = 0 # Taux d'intérêt domestique
r_star = 0 # Taux d'intérêt étrangé
mu = 0.5 # Coefficient d'aversion au risque

# Création des datasets d'entraînement
datasets = {}

for i, key in enumerate (data.keys()):

    sim = f'Sim_{i+1}'

    # Variation du taux de change pour la simulation
    ΔS = pd.Series(data[key]['S']).diff()

    datasets[sim] = {}
    datasets[sim]['S_ref'] = data[key]['S']
    datasets[sim]['ΔS_ref'] = ΔS.to_list()
    datasets[sim]['s_star'] = data[key]['S_star']
    datasets[sim]['E_f'] = data[key]['E_f']
    datasets[sim]['E_c'] = data[key]['E_c']
    datasets[sim]['W_f'] = data[key]['W_f']
    datasets[sim]['W_c'] = data[key]['W_c']

    # Création des retards, des mises en puissance et des interactions entre variables
    df = pd.DataFrame(ΔS[:n3], columns = [sim])

    for lag in range(1, number_lags + 1):
        df['Lag_' + str(lag)] = df[sim].shift(lag, fill_value = 0)

    df.dropna(inplace = True)

    poly = PolynomialFeatures(degree = degree_poly, include_bias=False, interaction_only
↳ = False)
    lags = [f'Lag_{x+1}' for x in range(number_lags)]
    poly_fitted = poly.fit_transform(df[lags])[:, number_lags:]
    lag_interaction = poly.get_feature_names(lags)[number_lags:]
    df[lag_interaction] = pd.DataFrame(poly_fitted,

```

```

index = df.index)

scaler = StandardScaler()

# Stocke le nom des colonnes, le scaler, X (features), y (target)
datasets[sim]['colnames'] = df.columns
datasets[sim]['X'] = scaler.fit_transform(df.drop([sim], axis = 1))
datasets[sim]['y'] = df[sim].values.reshape(-1, 1)
datasets[sim]['scaler'] = scaler

# Entraînement des modèles LASSO

lasso_models = {}

# Valeurs à tester pour les hyperparamètres
param_grid = {'alpha' : np.arange(0, 1.01, 0.01)}

# Validation croisée spécialement conçue pour les séries temporelles
tscv = TimeSeriesSplit(n_splits=5)

for n, sim in enumerate(datasets.keys()):

    # LASSO
    lasso = GridSearchCV(Lasso(), param_grid, cv = tscv, n_jobs = -1)
    lasso.fit(datasets[sim]['X'], datasets[sim]['y'])
    lasso_models[sim] = lasso.best_estimator_ # retrouve le meilleur estimateur parmi
    → ceux testés avec GridSearchCV

# Remplacement Chartist par ML

# Fixation du seed pour retomber sur les mêmes résultats
np.random.seed(440)

poly = PolynomialFeatures(degree = degree_poly, include_bias=False, interaction_only =
    → False)
results = {}

# Remplacement des agents chartistes dans les différentes simulations
for n, sim in enumerate(datasets.keys()):

    print(f"Début de l'itération {n+1} sur {n2}")

    results[sim] = {}

```

```

# Création et initialisation des vecteurs et des matrices de résultats
s = [0 for x in range((n1 + 1))]
Δs = [0 for x in range((n1 + 1))]
s_star = datasets[sim]['s_star']
w_c = [0 for x in range (n1)]
w_f = [0 for x in range(n1)]
E_f = [0 for x in range(n1)]
E_c = [0 for x in range(n1)]
pi_f = [0 for x in range(n1)]
pi_c = [0 for x in range(n1)]
sigma2_f = [0 for x in range(n1)]
sigma2_c = [0 for x in range(n1)]
pi_prime_f = [0 for x in range(n1)]
pi_prime_c = [0 for x in range(n1)]

# Jusqu'à l'observation n3 (comprise), les données sont similaires aux données
↳ d'entraînement
# car avant le remplacement de la règle chartiste par une règle plus sophistiquée
for i in range (n3+1):
    s[i] = datasets[sim]['S_ref'][i]
    Δs[i] = datasets[sim]['ΔS_ref'][i]

for i in range (n3):
    w_c[i] = datasets[sim]['W_c'][i]
    w_f[i] = datasets[sim]['W_f'][i]
    E_c[i] = datasets[sim]['E_c'][i]
    E_f[i] = datasets[sim]['E_f'][i]

# Création des variables indépendantes et standardisation
for i in range(n3, n1):

    lags = []

    for lag in range(0, number_lags):

        lags.append(Δs[i - lag])

    features = poly.fit_transform(np.asarray(lags).reshape(1,-1))

# Standardisation des variables indépendantes
scaled_features = datasets[sim]['scaler'].transform(features)

# Prédiction au temps i du taux de change au temps i + 1 pour chaque type
↳ d'agent (F et C):

```

```

E_f[i] = (1 - psi) * s[i] + psi * s_star[i]
E_c[i] = s[i] + beta*lasso_models[sim].predict(scaled_features)

# Valeurs des profits non-ajustés selon les deux règles (F et C) :
pi_f[i] = (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+
↳ r_star)*E_f[i-1]-(1+r)*s[i-1])
pi_c[i] = (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+
↳ r_star)*E_c[i-1]-(1+r)*s[i-1])

# Valeurs des variances associées aux erreurs de prévision selon les deux règles
↳ (mesure du risque) :
sigma2_f[i] = (E_f[i-1]-s[i])**2
sigma2_c[i] = (E_c[i-1]-s[i])**2

# Valeurs des profits ajustés :
pi_prime_f[i] = pi_f[i] - mu*sigma2_f[i]
pi_prime_c[i] = pi_c[i] - mu*sigma2_c[i]

# Evaluation des poids de chaque type d'agents
w_f[i] = float((np.exp(gamma*pi_prime_f[i]))/(np.exp(gamma*pi_prime_f[i]) +
↳ np.exp(gamma*pi_prime_c[i])))
w_c[i] = float((np.exp(gamma*pi_prime_c[i]))/(np.exp(gamma*pi_prime_f[i]) +
↳ np.exp(gamma*pi_prime_c[i])))

# Taux de change :
s[i+1] = float((s[i]-w_f[i]*psi*(s[i]-s_star[i])+w_c[i]*(E_c[i]-s[i])) +
↳ np.random.normal(0, 0.1, 1))

# Variation du taux de change :
Δs[i+1] = float(s[i+1] - s[i])

# La colonne j des différentes matrices output correspond aux séries générées
# correspondantes issues de la boucle interne pour la jième simulation
results[sim]['S'] = s
results[sim]['S_star'] = s_star
results[sim]['E_f'] = E_f
results[sim]['E_c'] = E_c
results[sim]['W_f'] = w_f
results[sim]['W_c'] = w_c

results[sim]['S'] = np.delete(results[sim]['S'], n1, 0).tolist()

print("Fin")

```

```

moments_dict = {}

for sim in results.keys():

    moments = {}

    for key in results[sim].keys():

        moments[key] = []

        for value in results[sim][key]:

            # Parce que JSON ne permet pas le stockage d'array
            try:
                moments[key].append(value.item())
            except:
                moments[key].append(value)
        moments_dict[sim] = moments

# Sauvegarde des simulations et des données importantes dans un fichier json
with open(f'DG_lasso_replacement_{beta}_{gamma}_{mu}.json', 'w') as outfile:
    json.dump(moments_dict, outfile)

```

8.1.3. Code - Ajout des agents chartistes machine learner

```

# Importation des librairies

import scipy
from scipy.ndimage.interpolation import shift

import random

import numpy as np
from numpy import arange

import math

import matplotlib.pyplot as plt

import pandas as pd

from sklearn.linear_model import LinearRegression, Lasso, Ridge, ElasticNet

```

```

from sklearn.preprocessing import RobustScaler, PolynomialFeatures, StandardScaler,
    ↳ MinMaxScaler
from sklearn.model_selection import GridSearchCV, train_test_split, TimeSeriesSplit
from sklearn.pipeline import Pipeline

import json

import warnings
warnings.filterwarnings('ignore')

# Chargement des données du modèle de référence
with open('DG_référence_0.9_5_0.5.json') as json_file:
    data = json.load(json_file)

# Paramètres

n1 = len(data['Sim_1']['S']) # Nombre d'observations par simulation
n2 = len(data) # Nombre de simulations
n3 = 5000 # Période à laquelle la nouvelle règle est introduite

number_lags = 4 # Nombre de retards (variation du taux de change) pris en compte dans la
    ↳ règle ML
degree_poly = 3 # degré du polynome

psi = 0.2 # le coefficient de la règle fondamentaliste (% de mauvais alignement attendu
    ↳ à être corrigé)
beta = 0.9 # Le coefficient de la règle chartiste (paramètre d'extrapolation)
gamma = 5 # Mesure l'intensité avec laquelle les agents révisent leurs règles de
    ↳ prédiction

r = 0 # Taux d'intérêt domestique
r_star = 0 # Taux d'intérêt étrangé
mu = 0.5 # Coefficient d'aversion au risque

# Création des datasets d'entraînement
datasets = {}

for sim in data.keys():

    # Variation du taux de change pour la simulation
    ΔS = pd.Series(data[sim]['S']).diff()

    datasets[sim] = {}

```

```

datasets[sim]['S_ref'] = data[sim]['S']
datasets[sim]['ΔS_ref'] = ΔS.to_list()
datasets[sim]['s_star'] = data[sim]['S_star']
datasets[sim]['E_f'] = data[sim]['E_f']
datasets[sim]['E_c'] = data[sim]['E_c']
datasets[sim]['W_f'] = data[sim]['W_f']
datasets[sim]['W_c'] = data[sim]['W_c']

# Création des retards, des mises en puissance et des interactions entre variables
df = pd.DataFrame(ΔS[:n3], columns = [sim])

for lag in range(1, number_lags + 1):
    df['Lag_' + str(lag)] = df[sim].shift(lag, fill_value = 0)

df.dropna(inplace = True)

poly = PolynomialFeatures(degree = degree_poly, include_bias=False, interaction_only
↪ = False)
lags = [f'Lag_{x+1}' for x in range(number_lags)]
poly_fitted = poly.fit_transform(df[lags][:, number_lags:])
lag_interaction = poly.get_feature_names(lags)[number_lags:]
df[lag_interaction] = pd.DataFrame(poly_fitted,
                                index = df.index)

scaler = StandardScaler()

# Stocke le nom des colonnes, le scaler, X (features), y (target)
datasets[sim]['colnames'] = df.columns
datasets[sim]['X'] = scaler.fit_transform(df.drop([sim], axis = 1))
datasets[sim]['y'] = df[sim].values.reshape(-1, 1)
datasets[sim]['scaler'] = scaler

# Entraînement des modèles LASSO

lasso_models = {}

# Valeurs à tester pour les hyperparamètres
param_grid = {'alpha' : np.arange(0, 1.01, 0.01)}

# Validation croisée spécialement conçue pour les time series
tscv = TimeSeriesSplit(n_splits=5)

for n, sim in enumerate(datasets.keys()):

```

```

# LASSO
lasso = GridSearchCV(Lasso(), param_grid, cv = tscv, n_jobs = -1)
lasso.fit(datasets[sim]['X'], datasets[sim]['y'])
lasso_models[sim] = lasso.best_estimator_ # retrouve le meilleur estimateur parmi
↳ ceux testés avec GridSearchCV

# Introduction d'une nouvelle stratégie dans le modèle: Stratégie avec des agents
↳ chartistes ML

# Fixation du seed pour retomber sur les mêmes résultats
np.random.seed(440)

poly = PolynomialFeatures(degree = degree_poly, include_bias=False, interaction_only =
↳ False)
results = {}

for n, sim in enumerate(datasets.keys()):

    print(f"Début de l'itération {n+1} sur {n2}")

    results[sim] = {}

    # Création et initialisation des vecteurs et des matrices de résultats
    s = [0 for x in range((n1 + 1))]
    Δs = [0 for x in range((n1 + 1))]
    s_star = datasets[sim]['s_star']
    w_c = [0 for x in range (n1)]
    w_f = [0 for x in range(n1)]
    w_m = [0 for x in range (n1)]
    E_f = [0 for x in range(n1)]
    E_c = [0 for x in range(n1)]
    E_m = [0 for x in range (n1)]
    pi_f = [0 for x in range(n1)]
    pi_c = [0 for x in range(n1)]
    pi_m = [0 for x in range (n1)]
    sigma2_f = [0 for x in range(n1)]
    sigma2_c = [0 for x in range(n1)]
    sigma2_m = [0 for x in range (n1)]
    pi_prime_f = [0 for x in range(n1)]
    pi_prime_c = [0 for x in range(n1)]
    pi_prime_m = [0 for x in range (n1)]

    # Jusqu'à l'observation n3 (comprise), les données sont similaires aux données
    ↳ d'entraînement

```

```

# car avant l'ajout de la règle chartiste plus sophistiquée
for i in range(n3+1):
    s[i] = datasets[sim]['S_ref'][i]
    Δs[i] = datasets[sim]['ΔS_ref'][i]

for i in range(n3):
    w_c[i] = datasets[sim]['W_c'][i]
    w_f[i] = datasets[sim]['W_f'][i]
    E_c[i] = datasets[sim]['E_c'][i]
    E_f[i] = datasets[sim]['E_f'][i]

# Prédiction des agents ML en n3-1 pour s en n3 nécessaire pour déterminer la
→ rentabilité passée de la stratégie ML
# en n3 et le risque en n3
# D'abord il nous faut notre vecteur de features

lags = []
for lag in range(1, number_lags + 1):

    lags.append(Δs[n3 - lag])

features = poly.fit_transform(np.asarray(lags).reshape(1,-1))

# Standardisation des variables indépendantes
scaled_features = datasets[sim]['scaler'].transform(features)

E_m[n3-1] = float(s[n3-1] + beta*lasso_models[sim].predict(scaled_features))
# E(s[n3]) = s[n3-1] + E(delta S[n3])

# Création des variables indépendantes et standardisation
for i in range(n3, n1):

    lags = []

    # Créer les lags
    for lag in range(0, number_lags):
        lags.append(Δs[i - lag])

    features = poly.fit_transform(np.asarray(lags).reshape(1,-1))

    # Standardisation des variables indépendantes
    scaled_features = datasets[sim]['scaler'].transform(features)

# Prédiction au temps i de taux de change au temps i + 1 pour chaque type
→ d'agent (F, C et M):

```

```

E_f[i] = float((1 - psi) * s[i] + psi * s_star[i])
E_c[i] = float((1 + beta) * s[i] - beta * s[i-1])
E_m[i] = float(s[i] + beta*lasso_models[sim].predict(scaled_features))

# Valeurs des profits non-ajustés selon les deux règles (F, C et M) :
pi_f[i] = (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+
↳ r_star)*E_f[i-1]-(1+r)*s[i-1])
pi_c[i] = (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+
↳ r_star)*E_c[i-1]-(1+r)*s[i-1])
pi_m[i] = (s[i]*(1+r_star)-s[i-1]*(1+r))*np.sign((1+
↳ r_star)*E_m[i-1]-(1+r)*s[i-1])

# Valeurs des variances associées aux erreurs de prévision selon les différentes
↳ règles (mesure du risque) :
sigma2_f[i] = (E_f[i-1]-s[i])**2
sigma2_c[i] = (E_c[i-1]-s[i])**2
sigma2_m[i] = (E_m[i-1]-s[i])**2

# Valeurs des profits ajustés :
pi_prime_f[i] = pi_f[i] - mu*sigma2_f[i]
pi_prime_c[i] = pi_c[i] - mu*sigma2_c[i]
pi_prime_m[i] = pi_m[i] - mu*sigma2_m[i]

# Evaluation des poids de chaque type d'agents
w_f[i] = float((np.exp(gamma*pi_prime_f[i]))/(np.exp(gamma*pi_prime_f[i]) +
↳ np.exp(gamma*pi_prime_c[i]) + np.exp(gamma*pi_prime_m[i])))
w_c[i] = float((np.exp(gamma*pi_prime_c[i]))/(np.exp(gamma*pi_prime_f[i]) +
↳ np.exp(gamma*pi_prime_c[i]) + np.exp(gamma*pi_prime_m[i])))
w_m[i] = float((np.exp(gamma*pi_prime_m[i]))/(np.exp(gamma*pi_prime_f[i]) +
↳ np.exp(gamma*pi_prime_c[i]) + np.exp(gamma*pi_prime_m[i])))

# Taux de change :
s[i+1] = float((s[i] - w_f[i]*psi*(s[i]-s_star[i]) + w_c[i]*beta*(s[i]-s[i-1]) +
↳ w_m[i]*(E_m[i]-s[i])) + np.random.normal(0, 0.1, 1))

# Variation du taux de change :
Δs[i+1] = float(s[i+1] - s[i])

# La colonne j des différentes matrices output correspond aux séries générées
# correspondantes issues de la boucle interne pour la jième simulation
results[sim]['S'] = s
results[sim]['ΔS'] = Δs
results[sim]['W_f'] = w_f
results[sim]['W_c'] = w_c

```

```

results[sim]['W_m'] = w_m
results[sim]['E_f'] = E_f
results[sim]['E_c'] = E_c
results[sim]['E_m'] = E_m
results[sim]['S_star'] = s_star

results[sim]['S'] = np.delete(results[sim]['S'], n1, 0)

print("Fin")

moments_dict = {}

for sim in results.keys():

    moments = {}

    for key in results[sim].keys():

        moments[key] = []

        for value in results[sim][key]:

            # Parce que JSON ne permet pas le stockage d'array
            try:
                moments[key].append(value.item())
            except:
                moments[key].append(value)
        moments_dict[sim] = moments

# saving dans un fichier json (évite de recalculer à chaque fois les séries)
with open(f'DG_lasso_ajout_{beta}_{gamma}_{mu}.json', 'w') as outfile:
    json.dump(moments_dict, outfile)

```

8.2. Remplacement des agents chartistes - Analyse de sensibilité

8.2.1. Degré d'extrapolation des agents chartistes

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0.3351	0.3441	0.3554	0.3704	0.3911	0.4219	0.4755	0.8611	24.2725
Extension	0.3267	0.329	0.3306	0.3334	0.3376	0.3442	0.3545	1.0373	14.6451
Levene p-value	0.3509	0.4975	0.497	0.5658	0.6596	0.0388	0	0.4574	0.1696
Shapiro-Wilk p-value	0.83	0.94	0.89	0.8	0.3	0.76	0	0	0
Test	Student	Student	Student	Student	Student	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0	0	0	0

Table 8.2.1 – Analyse de sensibilité - Beta : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	23.43	1584.1
Extension	0	0	0	0	0	0	0	87.95	1155.63
Levene p-value	Non pertinent	0.32	0.46						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.34	0						

Table 8.2.2 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.39	707.66
Extension	0	0	0	0	0	0	0	0	382.28
Levene p-value	Non pertinent	0.32	0.07						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.16	0						

Table 8.2.3 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	23.04	876.44
Extension	0	0	0	0	0	0	0	87.95	773.35
Levene p-value	Non pertinent	0.32	0.68						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.51	0						

Table 8.2.4 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.01	1.04
Extension	0	0	0	0	0	0	0	0	0.23
Levene p-value	Non pertinent	0.32	0						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.16	0						

Table 8.2.5 – Analyse de sensibilité - Beta : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L’hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l’extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.06	1.18
Extension	0	0	0	0	0	0	0	0.06	0.16
Levene p-value	Non pertinent	1	0						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.5	0						

Table 8.2.6 – Analyse de sensibilité - Beta : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L’hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l’extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Moyenne Référence	Non pertinent	39	973.6						
Moyenne Extension	Non pertinent	2780.92							
Levene p-value	Non pertinent	0.02							
Shapiro-Wilk p-value	Non pertinent	0							
Test	Non pertinent	Wilcoxon							
Test p-value	Non pertinent	0							

Table 8.2.7 – Analyse de sensibilité - Beta : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Moyenne Référence	Non pertinent	384	974.85						
Moyenne Extension	Non pertinent	2879.5	4833.44						
Levene p-value	Non pertinent	0	0.03						
Shapiro-Wilk p-value	Non pertinent	0.89	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.17	0						

Table 8.2.8 – Analyse de sensibilité - Beta : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.2.2. Sensibilité des agents à la profitabilité des heuristiques

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0.3578	0.3833	0.4265	24.2725	61.4211	61.0494
Extension	0.3282	0.3348	0.3446	14.6451	59.6074	58.803
Levene p-value	0.1815	0.5968	0.0526	0.1696	0.0431	0.1183
Shapiro-Wilk p-value	0.58	0.35	0.91	0	0	0
Test	Student	Student	Student	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0.245	0.2118

Table 8.2.9 – Analyse de sensibilité - Gamma : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	1584.1	3992.23	4025.72
Extension	0	0	0	1155.63	3849.35	3696.02
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.46	0.4	0.07
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.99	0.89

Table 8.2.10 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	707.66	1783.04	1920.43
Extension	0	0	0	382.28	1781.64	1711.91
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.07	0.65	0.84
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.12	0.07

Table 8.2.11 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
μ - Référence	0	0	0	876.44	2209.19	2105.29
μ - Extension	0	0	0	773.35	2067.71	1984.11
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.68	0.59	0.47
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.08	0.1

Table 8.2.12 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	1.04	1.81	2.58
Extension	0	0	0	0.23	0.79	1.05
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0

Table 8.2.13 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
μ - Référence	0	0	0	1.18	1.69	2.02
μ - Extension	0	0	0	0.16	0.51	0.84
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0

Table 8.2.14 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Moyenne Référence	Non pertinent	Non pertinent	Non pertinent	973.6	1826.64	1613.78
Moyenne Extension	Non pertinent	Non pertinent	Non pertinent	2780.92	3588.91	2899.33
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.02	0.79	0.05
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0

Table 8.2.15 – Analyse de sensibilité - Gamma : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Moyenne Référence	Non pertinent	Non pertinent	Non pertinent	974.85	2270.79	2069.19
Moyenne Extension	Non pertinent	Non pertinent	Non pertinent	4833.44	4551.68	3346.39
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.03	0	0.77
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0.01

Table 8.2.16 – Analyse de sensibilité - Gamma : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.2.3. Nombre de retards considérés par les agents machine learner

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	24.2725	24.2725	24.2725	24.2725	24.2725	24.2725
Extension	14.5732	14.5836	14.6207	14.6451	15.1311	15.6024
Levene p-value	0.1647	0.1643	0.1673	0.1696	0.2141	0.2682
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.17 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1584.1	1584.1	1584.1	1584.1	1584.1	1584.1
Extension	1139.29	1149.99	1154.59	1155.63	1190.29	1222.89
Levene p-value	0.42	0.45	0.46	0.46	0.56	0.66
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.18 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	707.66	707.66	707.66	707.66	707.66	707.66
Extension	367.14	375.81	381.24	382.28	416.94	449.54
Levene p-value	0.06	0.06	0.07	0.07	0.12	0.18
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.19 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	876.44	876.44	876.44	876.44	876.44	876.44
Extension	772.15	774.18	773.35	773.35	773.35	773.35
Levene p-value	0.68	0.68	0.68	0.68	0.68	0.68
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.20 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1.04	1.04	1.04	1.04	1.04	1.04
Extension	0.17	0.25	0.24	0.23	0.24	0.23
Levene p-value	0	0	0	0	0	0
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.21 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1.18	1.18	1.18	1.18	1.18	1.18
Extension	0.17	0.18	0.16	0.16	0.16	0.16
Levene p-value	0	0	0	0	0	0
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.22 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Moyenne Référence	973.6	973.6	973.6	973.6	973.6	973.6
Moyenne Extension	2834.83	2727.15	2855.37	2780.92	2954.89	3335.77
Levene p-value	0.02	0.01	0.03	0.02	0.03	0.11
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.23 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Moyenne Référence	974.85	974.85	974.85	974.85	974.85	974.85
Moyenne Extension	4542.06	4551.56	4833.44	4833.44	4833.44	4833.44
Levene p-value	0.23	0.21	0.03	0.03	0.03	0.03
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.2.24 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.2.4. Algorithme utilisé par les agents machine learner

Comparaison Modèles	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
	24.27	14.65	14.55	14.58	14.75	0.56	0.0	Kruskal-Wallis	0.0

Table 8.2.25 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	5.738964e-12
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	9.314945e-13
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.768847e-10
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.857098e-10
Référence	5.738964e-12	9.314945e-13	3.768847e-10	3.857098e-10	1.000000e+00

Table 8.2.26 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	1584.1	1155.63	1144.88	1145.92	1175.74	0.95	0.0	Kruskal-Wallis	0.0

Table 8.2.27 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes d’instabilité moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.502104e-09
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.396793e-09
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.187821e-09
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.235582e-09
Référence	1.502104e-09	1.396793e-09	2.187821e-09	2.235582e-09	1.000000e+00

Table 8.2.28 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes d’instabilité moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	707.66	382.28	372.21	373.27	403.0	0.26	0.0	Kruskal-Wallis	0.0

Table 8.2.29 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de bulle moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	5.493045e-13
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	5.349433e-13
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.586436e-13
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.734966e-13
Référence	5.493045e-13	5.349433e-13	4.586436e-13	4.734966e-13	1.000000e+00

Table 8.2.30 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de bulle moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	792.05	577.82	572.44	572.96	587.87	0.56	0.0	Kruskal-Wallis	0.0

Table 8.2.31 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de krach moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.852523e-21
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.705640e-21
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	8.644274e-21
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	8.723010e-21
Référence	3.852523e-21	3.705640e-21	8.644274e-21	8.723010e-21	1.000000e+00

Table 8.2.32 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de krach moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	1.04	0.23	0.18	0.2	0.22	0.0	0.0	Kruskal-Wallis	0.0

Table 8.2.33 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de bulles moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	7.610416e-16
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	7.722817e-16
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	5.773813e-16
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	8.432427e-16
Référence	7.610416e-16	7.722817e-16	5.773813e-16	8.432427e-16	1.000000e+00

Table 8.2.34 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de bulles moyen par simulation - Test de Dunn.

Comparaison Modèles	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
	1.11	0.2	0.18	0.19	0.19	0.0	0.0	Kruskal-Wallis	0.0

Table 8.2.35 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de krachs moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.856530e-31
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.899770e-31
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.468784e-30
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.184712e-30
Référence	3.856530e-31	3.899770e-31	1.468784e-30	2.184712e-30	1.000000e+00

Table 8.2.36 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de krachs moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	973.6	2780.92	2895.05	2727.41	2828.99	0.0	0.0	Kruskal-Wallis	0.0

Table 8.2.37 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des bulles - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.006434
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.011759
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.006007
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.011380
Référence	0.006434	0.011759	0.006007	0.01138	1.000000

Table 8.2.38 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des bulles - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	974.25	3997.23	3895.59	3829.68	4014.55	0.89	0.0	Kruskal-Wallis	0.0

Table 8.2.39 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des krachs - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.333238e-10
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	6.363069e-10
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.227691e-09
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.325628e-09
Référence	4.333238e-10	6.363069e-10	2.227691e-09	4.325628e-09	1.000000e+00

Table 8.2.40 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des krachs - Test de Dunn.

8.3. Ajout des agents chartistes - Analyse de sensibilité

8.3.1. Degré d'extrapolation des agents chartistes

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0.3351	0.3441	0.3554	0.3704	0.3911	0.4219	0.4755	0.8611	24.2725
Extension	0.4046	0.408	0.4153	0.4262	0.4411	0.4633	0.4992	1.0758	14.9264
Levene p-value	0	0	0	0	0.0001	0.0072	0.4598	0.621	0.1571
Shapiro-Wilk p-value	0.12	0.13	0.1	0.06	0.04	0.1	0.04	0	0
Test	Wilcoxon								
Test p-value	1	1	1	1	1	1	1	0	0

Table 8.3.1 – Analyse de sensibilité - Beta : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	23.43	1584.1
Extension	0	0	0	0	0	0	0	50	1178.78
Levene p-value	Non pertinent	0.62	0.52						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.16	0						

Table 8.3.2 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.39	707.66
Extension	0	0	0	0	0	0	0	0	371.37
Levene p-value	Non pertinent	0.32	0.06						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.16	0						

Table 8.3.3 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	23.04	876.44
Extension	0	0	0	0	0	0	0	50	807.41
Levene p-value	Non pertinent	0.61	0.79						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.29	0						

Table 8.3.4 – Analyse de sensibilité - Beta : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.01	1.04
Extension	0	0	0	0	0	0	0	0	0.28
Levene p-value	Non pertinent	0.32	0						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.16	0						

Table 8.3.5 – Analyse de sensibilité - Beta : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Référence	0	0	0	0	0	0	0	0.06	1.18
Extension	0	0	0	0	0	0	0	0.01	0.29
Levene p-value	Non pertinent	0.25	0						
Shapiro-Wilk p-value	Non pertinent	0	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.28	0						

Table 8.3.6 – Analyse de sensibilité - Beta : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Moyenne Référence	Non pertinent	39	973.6						
Moyenne Extension	Non pertinent	1498.41							
Levene p-value	Non pertinent	0.18							
Shapiro-Wilk p-value	Non pertinent	0							
Test	Non pertinent	Wilcoxon							
Test p-value	Non pertinent	0.31							

Table 8.3.7 – Analyse de sensibilité - Beta : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Beta = 0.1	Beta = 0.2	Beta = 0.3	Beta = 0.4	Beta = 0.5	Beta = 0.6	Beta = 0.7	Beta = 0.8	Beta = 0.9
Moyenne Référence	Non pertinent	384	974.85						
Moyenne Extension	Non pertinent	5000	3228.15						
Levene p-value	Non pertinent	0	0.02						
Shapiro-Wilk p-value	Non pertinent	1	0						
Test	Non pertinent	Wilcoxon	Wilcoxon						
Test p-value	Non pertinent	0.33	0						

Table 8.3.8 – Analyse de sensibilité - Beta : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.3.2. Sensibilité des agents à la profitabilité des heuristiques

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0.3578	0.3833	0.4265	24.2725	61.4211	61.0494
Extension	0.4237	0.4498	0.4872	14.9264	58.2979	58.6782
Levene p-value	0.0001	0.0001	0.0033	0.1571	0.1927	0.6574
Shapiro-Wilk p-value	0.07	0.1	0.2	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	1	1	1	0	0.1492	0.2622

Table 8.3.9 – Analyse de sensibilité - Gamma : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	1584.1	3992.23	4025.72
Extension	0	0	0	1178.78	3949.92	4013.37
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.52	0.66	0.65
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.89	0.84

Table 8.3.10 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	707.66	1783.04	1920.43
Extension	0	0	0	371.37	1824.49	1832.91
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.06	0.63	0.54
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.43	0.19

Table 8.3.11 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	876.44	2209.19	2105.29
Extension	0	0	0	807.41	2125.43	2180.46
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.79	0.57	0.16
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.28	0.37

Table 8.3.12 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	1.04	1.81	2.58
Extension	0	0	0	0.28	1.61	1.68
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0	0.82	0.02
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.1	0

Table 8.3.13 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Référence	0	0	0	1.18	1.69	2.02
Extension	0	0	0	0.29	1.16	1.88
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0	0.1	0.84
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.01	0.05

Table 8.3.14 – Analyse de sensibilité - Gamma : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Moyenne Référence	Non pertinent	Non pertinent	Non pertinent	973.6	1826.64	1613.78
Moyenne Extension	Non pertinent	Non pertinent	Non pertinent	1498.41	2303.81	2209.32
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.18	0.13	0.1
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0.31	0.15	0.06

Table 8.3.15 – Analyse de sensibilité - Gamma : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Gamma = 0	Gamma = 1	Gamma = 2	Gamma = 5	Gamma = 10	Gamma = 20
Moyenne Référence	Non pertinent	Non pertinent	Non pertinent	974.85	2270.79	2069.19
Moyenne Extension	Non pertinent	Non pertinent	Non pertinent	3228.15	3033.64	2639.45
Levene p-value	Non pertinent	Non pertinent	Non pertinent	0.02	0.66	0.06
Shapiro-Wilk p-value	Non pertinent	Non pertinent	Non pertinent	0	0	0
Test	Non pertinent	Non pertinent	Non pertinent	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	Non pertinent	Non pertinent	Non pertinent	0	0.07	0.16

Table 8.3.16 – Analyse de sensibilité - Gamma : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.3.3. Nombre de retards considérés par les agents machine learner

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	24.2725	24.2725	24.2725	24.2725	24.2725	24.2725
Extension	14.981	15.0009	14.8719	14.9264	15.0979	14.8309
Levene p-value	0.1587	0.1582	0.1514	0.1571	0.1733	0.1575
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.17 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après le remplacement des agents. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1584.1	1584.1	1584.1	1584.1	1584.1	1584.1
Extension	1139.02	1142.5	1129.95	1178.78	1203.85	1156.54
Levene p-value	0.4	0.41	0.38	0.52	0.6	0.46
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.18 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes d'instabilité par simulation. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	707.66	707.66	707.66	707.66	707.66	707.66
Extension	351.82	352.43	350.43	371.37	383.82	384.14
Levene p-value	0.04	0.04	0.04	0.06	0.07	0.07
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.19 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes de bulle. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	876.44	876.44	876.44	876.44	876.44	876.44
Extension	787.2	790.07	779.52	807.41	820.03	772.4
Levene p-value	0.72	0.73	0.69	0.79	0.83	0.67
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.20 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de périodes de krach. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1.04	1.04	1.04	1.04	1.04	1.04
Extension	0.26	0.32	0.31	0.28	0.24	0.21
Levene p-value	0	0	0	0	0	0
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.21 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Référence	1.18	1.18	1.18	1.18	1.18	1.18
Extension	0.4	0.36	0.34	0.29	0.31	0.27
Levene p-value	0	0	0	0	0	0
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.22 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des nombres moyens de krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est inférieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Moyenne Référence	973.6	973.6	973.6	973.6	973.6	973.6
Moyenne Extension	1596.01	1393.02	1414.76	1498.41	1937.76	2235.14
Levene p-value	0.19	0.27	0.27	0.18	0.04	0.03
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0.18	0.43	0.39	0.31	0.14	0.02

Table 8.3.23 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des durées moyennes des bulles. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

	Nb retards = 1	Nb retards = 2	Nb retards = 3	Nb retards = 4	Nb retards = 5	Nb retards = 6
Moyenne Référence	974.85	974.85	974.85	974.85	974.85	974.85
Moyenne Extension	2534.3	2558.31	2762.42	3228.15	3366.27	3490.16
Levene p-value	0	0	0	0.02	0.05	0.11
Shapiro-Wilk p-value	0	0	0	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0	0	0	0	0	0

Table 8.3.24 – Analyse de sensibilité - nombre de retards considérés par les agents : comparaison des durées moyennes des krachs. Nous utilisons des tests unilatéraux. L'hypothèse nulle de chaque test est que la moyenne du modèle de référence est supérieure ou égale à la moyenne de l'extension.

8.3.4. Algorithme utilisé par les agents machine learner

Comparaison Modèles	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
	24.27	14.93	14.75	14.75	14.9	0.5	0.0	Kruskal-Wallis	0.0

Table 8.3.25 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après l'ajout des agents - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.197566e-09
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.524786e-10
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.884081e-08
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.035315e-08
Référence	1.197566e-09	1.524786e-10	3.884081e-08	3.035315e-08	1.000000e+00

Table 8.3.26 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale pour les périodes après l'ajout des agents - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	1584.1	1178.78	1111.07	1110.56	1140.79	0.91	0.0	Kruskal-Wallis	0.0

Table 8.3.27 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes d’instabilité moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.197566e-09
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.524786e-10
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.884081e-08
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.035315e-08
Référence	1.197566e-09	1.524786e-10	3.884081e-08	3.035315e-08	1.000000e+00

Table 8.3.28 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes d’instabilité moyen par simulation - Test de Dunn.

Comparaison Modèles	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
	707.66	371.37	324.26	323.9	351.59	0.11	0.0	Kruskal-Wallis	0.0

Table 8.3.29 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de bulle moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.057289e-10
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.323332e-09
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.325935e-10
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.325935e-10
Référence	2.057289e-10	1.323332e-09	4.325935e-10	4.325935e-10	1.000000e+00

Table 8.3.30 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de bulle moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	792.05	589.39	555.54	555.28	570.4	0.46	0.0	Kruskal-Wallis	0.0

Table 8.3.31 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de krach moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.407612e-14
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.323439e-14
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	7.590154e-14
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	7.635578e-14
Référence	2.407612e-14	2.323439e-14	7.590154e-14	7.635578e-14	1.000000e+00

Table 8.3.32 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de périodes de krach moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	1.04	0.28	0.29	0.28	0.28	0.0	0.0	Kruskal-Wallis	0.0

Table 8.3.33 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de bulles moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	2.037977e-11
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.399134e-10
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	8.070082e-11
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	6.418119e-11
Référence	2.037977e-11	1.399134e-10	8.070082e-11	6.418119e-11	1.000000e+00

Table 8.3.34 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de bulles moyen par simulation - Test de Dunn.

Comparaison Modèles	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
	1.11	0.28	0.32	0.32	0.32	0.0	0.0	Kruskal-Wallis	0.0

Table 8.3.35 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de krachs moyen par simulation - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.522294e-20
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.863214e-20
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	4.274195e-19
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	3.550119e-19
Référence	4.522294e-20	1.863214e-20	4.274195e-19	3.550119e-19	1.000000e+00

Table 8.3.36 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison du nombre de krachs moyen par simulation - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	973.6	1498.41	1480.99	1483.61	1658.3	0.41	0.0	Kruskal-Wallis	0.95

Table 8.3.37 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des bulles - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00
Référence	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00

Table 8.3.38 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des bulles - Test de Dunn.

	Référence	LASSO	MCO	Ridge	Elastic Net	Levene p-v	Shapiro-Wilk p-v	Test	Test p-v
Comparaison Modèles	974.25	2468.75	2254.34	2236.43	2402.68	0.0	0.0	Kruskal-Wallis	0.0

Table 8.3.39 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des krachs - ANOVA.

	Elastic Net	LASSO	MCO	Ridge	Référence
Elastic Net	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.007020
LASSO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.005703
MCO	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.044557
Ridge	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	0.040765
Référence	0.00702	0.005703	0.044557	0.040765	1.000000

Table 8.3.40 – Analyse de sensibilité - algorithme utilisé par les agents : comparaison de la durée moyenne des krachs - Test de Dunn.

8.4. Comparaison des deux extensions

	Moyenne quadratique des écarts
Extension 1 (remplacement)	14.65
Extension 2 (ajout)	14.93
Levene p-value	0.99
Shapiro-Wilk p-value	0
Test	Wilcoxon
Test p-value	0

Table 8.4.1 – Comparaison des valeurs moyennes des moyennes quadratiques des écarts entre le taux de change et sa valeur fondamentale - test unilatéral utilisé avec comme hypothèse nulle : la moyenne de la première extension (remplacement) est supérieure ou égale à la moyenne de la seconde extension (ajout)

	Périodes d'instabilité	Périodes de bulle	Périodes de krach
Extension 1 (remplacement)	1155.63	382.28	773.35
Extension 2 (ajout)	1178.78	371.37	807.41
Levene p-value	0.94	0.95	0.89
Shapiro-Wilk p-value	0	0	0
Test	Wilcoxon	Wilcoxon	Wilcoxon
Test p-value	0.14	0.12	0.17

Table 8.4.2 – Comparaison des nombres moyens de périodes d'instabilité, de périodes de bulle et de périodes de krach - tests unilatéraux utilisés avec comme hypothèse nulle : la moyenne de la première extension (remplacement) est supérieure ou égale à la moyenne de la seconde extension (ajout)

	Nombre de bulles	Nombre de krachs
Extension 1 (remplacement)	0.23	0.16
Extension 2 (ajout)	0.28	0.29
Levene p-value	0.66	0.09
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0.09	0.09

Table 8.4.3 – Comparaison des nombres moyens de bulles et de krachs après l'introduction de la nouvelle heuristique - tests unilatéraux utilisés avec comme hypothèse nulle : la moyenne de la première extension (remplacement) est supérieure ou égale à la moyenne de la seconde extension (ajout)

	Durée des bulles	Durée des krachs
Extension 1 (remplacement)	2780.92	4833.44
Extension 2 (ajout)	1498.41	3228.15
Levene p-value	0.29	0
Shapiro-Wilk p-value	0	0
Test	Wilcoxon	Wilcoxon
Test p-value	0.03	0

Table 8.4.4 – Comparaison des durées moyennes des bulles et des krachs après l'introduction de la nouvelle heuristique - tests unilatéraux utilisés avec comme hypothèse nulle : la moyenne de la première extension (remplacement) est inférieure ou égale à la moyenne de la seconde extension (ajout)