

Mémoire de fin d'Etudes

Thème :

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Présenté et soutenu par :

Hiba DHAOUI

Encadré par :

Mr. Farouk KRIAA

Etudiant(e) parrainé(e) par :

BCT

Résumé

Ce travail présente une approche basée sur le Machine Learning pour la prévision de l'inflation, un problème redoutable et non résolu de la macroéconomie moderne.

Les défis sont dus à un comportement non linéaire et non stationnaire de l'inflation dans la pratique. Par conséquent, les modèles économétriques conventionnels ne parviennent pas à fournir des prévisions cohérentes et fiables, puisqu'ils ne sont pas bien équipés pour saisir cette complexité.

Dans ce contexte, les techniques de ML se présentent comme une approche prometteuse, compte tenu de son succès dans le traitement des séries temporelles.

Les modèles de ML proposés pour la prévision à court terme de l'inflation en Tunisie sont comparés à des références économétriques : VAR & SARIMA.

L'analyse empirique corrobore la supériorité du modèle de ML de type LSTM en termes de cohérence et de performance hors échantillon. La robustesse de ces résultats est confirmée par une validation croisée et des simulations utilisant différents échantillons d'apprentissage, de validation et de test.

Mots-clés : inflation, prévision, Machine Learning

Abstract

This work presents a Machine Learning-based approach for forecasting inflation, which is a daunting and unsolved problem in modern macroeconomics.

The challenges emerge due to the non-linear and non-stationary behavior of inflation in practice. As a result, conventional econometric models fail to provide consistent and reliable forecasts, since they are not well-equipped to capture this complexity.

In this context, ML techniques present themselves as a promising approach, given its success in handling time series.

The proposed ML models for short-term inflation forecasting in Tunisia are compared to econometric references: VAR & SARIMA.

The empirical analysis corroborates the superiority of the LSTM model in terms of consistency and out of sample performance. The robustness of these results is confirmed by cross-validation and simulations using different learning, validation and test samples.

Keywords: inflation, forecasting, Machine Learning

REMERCIEMENTS

*En préambule de ce mémoire, je tiens à remercier toutes les personnes qui ont contribué à la réalisation de ce travail. Mes vifs remerciements s'adressent à mon encadrant **M. Farouk Kriaa**, pour sa disponibilité, ses directives, ses conseils judicieux et son aide inestimable.*

*Je tiens à exprimer ma gratitude et reconnaissance, à **Mme. Hela Zghal**, Directrice Générale des Statistiques et **Mme. Nahed Tanfous**, Directrice des statistiques monétaires et financières, qui m'ont accueilli chaleureusement et m'ont été d'un grand aide, durant toute la période du stage. Leur compétence scientifique, leur esprit critique et le temps consacré à la correction de mon manuscrit m'ont permis de mieux structurer ce travail.*

Je remercie toute la famille de la BCT, pour son aide précieuse et ses conseils. Je souhaite également adresser mes remerciements à l'administration et à tous les enseignants de l'IFID pour leur assistance tout au long de notre parcours de formation.

LISTE DES ABREVIATIONS

ACF : Autocorrelation function

AD: Aggregate demand

ADAM: Adaptive Moment estimation

AI: Artificial intelligence

ANN : Artificial Neural Network

ARIMA: Autoregressive integrated moving average

AS: Aggregate supply

BCE : Banque centrale européenne

BCT : Banque centrale de Tunisie

CT: Court terme

DFM: Dynamic factor model

DSGE : Modèle d'équilibre général dynamique stochastique

FED : Federal Reserve

FMI : Fond monétaire internationale

FOMC : Federal Open Market Committee

GPM : Global projection model

IFC : Ivring Fisher Committe

INS : Institut national des statistiques

IPC : Indice de prix à la consommation

IPP : L'indice des prix à la production

KNN : K-Nearest Neighbors

LSTM: Long short term memory

MAE : Mean absolute error

MCO : Moindre carré ordinaire

ML: Machine Learning

MM : Macro Model

MPICT : Modèle de prévision de l'inflation à court terme

MSE: Mean Squared Error

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

NLP : Natural language processing

OCDE : Organisation de coopération et de développement économiques

PACF : Partial autocorrelation function

PIB: Produit intérieur brut

RMSE: Root Mean Squared Error

RNN: Recurrent Neural Network

RW : Random Walk

SARIMA: Seasonal autoregressive integrated moving average

TMM : Taux mensuel moyen de marché monétaire

VAR : Vecteur Autorégressif

VECM : Vector error correction model

LISTE DES FIGURES

Figure 1.Architecture du dispositif de prévision de la BCT.	28
Figure 2.Architecture simplifiée des arbres de régression	57
Figure 3.Représentation d'un perceptron à une seule couche	60
Figure 4.Perceptron multicouche	61
Figure 5.Graphique de neurone biologique (gauche) et réseau de neurones artificiels (droite) (source : Ghallou , 2017).....	63
Figure 6.Meilleures bibliothèques Python pour l'apprentissage statistique et l'apprentissage profond	70
Figure 7.La frontière de Pagan	74
Figure 8.Une image intuitive de la façon dont les données sont divisées dans l'approche de validation croisée pour les modèles de séries chronologiques.	78
Figure 9.Evolution de l'inflation en Tunisie de 2001 à 2020	83
Figure 10.Le graphique Q-Q	88
Figure 11.Histogramme relatif à l'inflation	88
Figure 12.Les fonctions d'autocorrélation et l'autocorrélation partielle de l'inflation	89
Figure 13.Nuage des points relatives à l'inflation et ses différents déterminants	93
Figure 14.Matrice de corrélation.	94
Figure 15.La sélection du modèle SARIMA.....	95
Figure 16.Prévision <i>out of sample</i> du modèle SARIMA	96
Figure 17.Prévision <i>out of sample</i> du modèle VAR	99
Figure 18.Illustration du comportement de MSE & MAE du modèle LSTM proposé dans ce travail pour la prévision de l'inflation en Tunisie.....	104
Figure 20.Prévision <i>out of sample</i> par le modèle LSTM	105

LISTE DES TABLEAUX

Tableau 1.Econométrie Versus Machine Learning	75
Tableau 2.Prévisions de l'inflation (moyenne annuelle)	85
Tableau 3.Evolution de l'indice des prix de vente industriel (Variation en %).	86
Tableau 4.Test de normalité	89
Tableau 5.Test de cointégration	98
Tableau 6.Test sur la stationnarité des résidus	98
Tableau 7.RMSE & MAE relatifs au modèle LSTM.....	105
Tableau 8.Comparaison des performances prédictives des modèles de ML par rapport au benchmark selon les deux métriques MSE & MAE	106

SOMMAIRE

INTRODUCTION GENERALE	10
CHAPITRE PREMIER : L'INFLATION & LA POLITIQUE MONETAIRE	13
Introduction	13
Section 1 : Vue générale sur l'inflation & les techniques de prévision	15
1. Définition de l'inflation.....	15
2. Types & mesures de l'inflation	15
3. Les mécanismes économiques de l'inflation.....	18
4. Les déterminants de l'inflation.....	22
Section 2 : Les techniques de prévisions de l'inflation	24
1. Revue de la littérature académique relative aux outils de prévision de l'inflation	24
2. Dispositifs de prévision de l'inflation dans les banques centrales	26
3. Les méthodes conventionnelles : Revue de la littérature	32
Section 3 : La politique monétaire et le contrôle de l'inflation.....	39
1. Définition et objectifs de la politique monétaire	39
2. Les instruments de la politique monétaire face à l'inflation	41
3. Les canaux de transmission de la politique monétaire	43
4. Le <i>reporting</i> des prévisions sur l'inflation & la transition au régime de ciblage d'inflation	47
Conclusion.....	48
CHAPITRE 2 : LES TECHNIQUES DE MACHINE LEARNING : PRINCIPE & APPLICATION EMPIRIQUE SUR DES DONNEES TUNISIENNES	50
Introduction	50
Section 1 : Contextualisation et généralités sur l'intelligence artificielle	52
Section 2 : Exploration des techniques de Machine Learning	53
1. Définition de Machine Learning :	53
2. Les types d'apprentissage :	54
3. Les algorithmes de Machine Learning	55
4. L'utilisation des techniques de Machine Learning dans la prévision de l'inflation.....	67
5. Le langage de programmation de Machine Learning & les bibliothèques clé.....	69

**PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR
DES DONNEES TUNISIENNES**

Section 3 : L'économétrie & les techniques de Machine Learning	72
1. L'économétrie Versus le Machine Learning	72
2. L'économétrie combinée avec les techniques de Machine Learning :.....	76
Section 4 : Une application sur des données tunisiennes	81
1. L'inflation en Tunisie : une analyse descriptive	81
2. Les variables de la base de données	90
3. Méthodologies & résultats	95
CONCLUSION GENERALE	109
BIBLIOGRAPHIE	112
TABLE DES MATIÈRES	122

INTRODUCTION GENERALE

L'étude de l'inflation et des modèles mathématiques permettant d'expliquer sa dynamique et de générer des prévisions est un sujet récurrent de la macroéconomie et de l'économétrie modernes. Son importance découle du rôle joué par l'inflation dans de nombreux contextes pratiques, essentiellement la mise en œuvre de la politique monétaire dans les banques centrales.

Ainsi, les décideurs dans les banques centrales s'appuient, entre autres, sur les prévisions d'inflation pour déterminer le taux d'intérêt directeur optimal.

En outre, l'épargne et la consommation des entreprises et des ménages sont influencées par l'inflation attendue. Cet indicateur est également crucial pour les institutions financières pour le calibrage des spreads de crédit.

Pour le cas de la Tunisie, la banque centrale prépare une feuille de route pour s'orienter progressivement vers un cadre de ciblage de l'inflation et une transition réussie vers ce régime dépend non seulement des conditions préalables à l'adoption de cette stratégie, mais aussi de la capacité à prévoir l'inflation à court et moyen terme.

La BCT utilise un large ensemble d'informations pour la prévision de l'inflation provenant de jugements d'experts et une variété de modèles allant de simples modèles traditionnels de séries temporelles à des modèles dynamiques d'équilibre général stochastique bien structurés sur le plan théorique.

Malgré l'importance de la prévision de l'inflation, il n'existe pas de consensus concernant la meilleure approche économétrique pour concevoir des prévisions fiables et utiles.

Les difficultés proviennent des propriétés empiriques complexes des séries chronologiques d'inflation observées, marquées par la non-stationnarité et les non-linéarités.

Les modèles économétriques standard n'ont généralement pas assez de flexibilité pour reproduire ces propriétés, car ils sont construits sur de nombreuses hypothèses simplificatrices incompatibles avec la réalité empirique.

Au cours des deux dernières décennies, nous assistons à une jonction critique de deux mégatendances qui ont révolutionné l'économétrie.

D'un côté, le développement spectaculaire des capacités de traitement et de stockage parallèlement aux progrès des outils d'analyse et de modélisation d'où l'émergence des applications basées sur l'apprentissage automatique, qui combinent des éléments de statistiques informatiques, d'optimisation mathématique, de reconnaissance des formes, d'analyse prédictive et d'intelligence artificielle.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

De l'autre côté, on assiste à une augmentation rapide de la quantité de données granulaires, souvent appelées Big Data.

De ce fait, les outils d'apprentissage automatique et de big data font une percée rapide dans la boîte à outils des banques centrales à travers le monde.

Selon le comité Irving Fisher sur les statistiques des banques centrales (IFC)¹, plus de 80 % d'entre elles utilisent couramment ces techniques pour dans divers domaines, notamment la politique monétaire, la recherche économique, la stabilité financière, la supervision, la réglementation (applications Suptech et Regtech) et la compilation de statistiques (Doerr et al (2021)).

Les banques centrales des économies avancées utilisent ces techniques innovantes relativement plus que les économies émergentes.

Etant donné que les algorithmes de Machine Learning sont largement utilisés dans tous les domaines où des données complexes apparaissent et leur application aux données économiques fait l'objet de recherches depuis des années, plusieurs banques centrales utilisent ces algorithmes comme une méthode alternative de prévision.

Le recours à ces techniques innovantes s'explique par le fait qu'elles sont exemptes d'hypothèses statistiques et plus robustes aux données manquantes et inexactes, capables de détecter et de dupliquer tout modèle non linéaire complexe dans les données en théorie (Gupta & Kashyap, 2015). Notamment, elles apprennent facilement à partir d'exemples et capturent les relations fonctionnelles subtiles entre les données, même lorsque ces relations sont difficiles à décrire ou inconnues. Cette capacité d'apprendre par l'expérience rendent ces approches très utiles pour résoudre de nombreux problèmes pratiques de prévision macroéconomique.

Ainsi, l'objectif principal de ce travail est d'étudier si les méthodes d'apprentissage statistique peuvent améliorer la précision des prévisions d'inflation hors échantillon par rapport aux modèles conventionnels généralement rencontrés dans la littérature.

Nous organisons le mémoire en deux chapitres. Le premier chapitre aborde les différents modèles théoriques couramment utilisés pour modéliser et prévoir l'inflation et examine les politiques mises en œuvre par la banque centrale pour contrôler l'inflation en Tunisie ainsi que l'importance du dispositif de la prévision de l'inflation pour la mise en œuvre de la politique monétaire.

¹ Le Comité Irving Fisher sur les statistiques des banques centrales (IFC) est un forum réunissant des économistes et des statisticiens de banques centrales, ainsi que d'autres personnes désireuses de participer à l'examen de questions statistiques intéressant les banques centrales.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Dans le second chapitre, nous discutons les principes des techniques de Machine Learning utilisées pour la prévision macroéconomique et la théorie sous-jacente.

Enfin, nous présentons une application empirique des algorithmes de ML sur des données tunisiennes comparativement à des benchmarks économétriques.

Les possibilités des extensions possibles du travail actuel sont également suggérées dans la conclusion, posant ainsi les bases de futurs projets dans ce domaine.

CHAPITRE PREMIER : L'INFLATION & LA POLITIQUE MONETAIRE

Introduction

Les prévisions des indicateurs macroéconomiques, tels que l'inflation, jouent un rôle primordial pour la prise de décision, au niveau des banques centrales. Comme l'influence de la politique monétaire sur l'économie fonctionne à travers des mécanismes de transmission avec un décalage important, les décideurs doivent prendre des décisions sur la manière de gérer les pressions inflationnistes ou déflationnistes à l'avance.

Compte tenu de ces décalages, il est largement reconnu que la politique monétaire doit être prospective et s'inscrit dans une perspective de moyen terme.

De ce fait, les prévisions macroéconomiques constituent un élément essentiel du mode opératoire des banques centrales et la publication des rapports sur l'inflation contribue à ancrer les attentes des entreprises et des ménages ce qui rend les décideurs plus efficaces dans la réalisation de leur objectif. L'ancrage de ces anticipations, c'est-à-dire leur stabilité dans le temps, est une condition nécessaire à la stabilité macroéconomique. Cela rend idéalement la prévision de l'inflation d'une grande importance pour maintenir la transparence de la mise en œuvre d'une politique monétaire crédible (Elliott & Timmerman, 2013).

De ce fait, les départements d'économie et de recherche ainsi que de politique monétaire dans les banques centrales s'efforcent d'intégrer dans leurs dispositifs de prévisions les derniers développements académiques.

Depuis 2016, l'objectif premier de la BCT est de "préserver la stabilité de prix" en s'orientant vers un cadre de ciblage de l'inflation et une flexibilité totale du taux de change.

Une transition réussie vers ce régime de ciblage de l'inflation exige des conditions préalables à l'adoption de cette stratégie soutenue par l'efficacité du dispositif de la prévision de l'inflation. Selon Laurens et al. (2015), l'expérience des différents pays suggère qu'une transition complète vers le cadre de ciblage de l'inflation peut prendre du temps et cela dépend des conditions macroéconomiques des pays et de la volonté de l'autorité de passer au régime de ciblage.

Kolsi et al. (2020) affirme dans une étude récente sur la base de l'expérience internationale et de l'expérience de BCT, la transition pourrait comprendre les éléments suivants :

- S'engager à mener une politique monétaire prospective fondée sur des règles,
- Annoncer un objectif d'inflation à moyen terme,
- Amélioration de la capacité analytique de la BCT et des modèles de macro-prévision,

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- Renforcer la communication, la transparence et la responsabilité.

Actuellement, la BCT fait appel à un large ensemble d'informations provenant des jugements d'experts, ainsi qu'une panoplie de techniques de prévisions allant de simples modèles traditionnels de séries temporelles à des modèles économétriques sophistiqués bien conçus.

Les informations utilisées pour l'évaluation globale des risques pesant sur "la stabilité des prix" et l'analyse des déterminants de l'inflation sont fournies par des outils analytiques : l'analyse économique, l'analyse monétaire et l'analyse des canaux de transmission.

L'analyse monétaire évalue les évolutions à moyen et long terme de l'inflation en se fondant sur la relation entre la monnaie et les prix sur de longues périodes. Cette analyse prend en compte les évolutions des indicateurs monétaires (dont M3, ses composantes et ses contreparties, notamment le crédit, et les mesures de l'excès de liquidité).

L'analyse économique identifie les risques à court et moyen terme pesant sur la stabilité des prix à travers le suivi régulier des variables économiques et financières non monétaires, telles que l'évolution de l'indice des prix à la consommation (IPC), de la production globale, du marché du travail et des indicateurs des marchés financiers.

Dans ce chapitre nous abordons en premier lieu une vue générale sur l'inflation, ses mesures, sa dynamique. En second lieu, on présente l'état de l'art des différentes techniques de prévision de l'inflation adoptées par les banques centrales.

Enfin, on expose le rôle de la politique monétaire dans le contrôle de l'inflation, les différentes mesures mises en place pour faire face à ce phénomène et l'importance du dispositif de prévision de l'inflation pour la transition au régime de ciblage de l'inflation.

Section 1 : Vue générale sur l'inflation & les techniques de prévision

1. Définition de l'inflation

L'inflation se définit comme la hausse généralisée et autoentretenu des prix des biens et services dans une économie sur une période donnée (McNabb & McKenna, 1990). Elle se traduit par une dépréciation du pouvoir d'achat de la monnaie attribuée à l'excès de liquidité, entraînant un déséquilibre entre l'offre et la demande globale.

Selon Parkin & Laidler (1975) : "L'inflation est un processus de hausse continue des prix ou, de manière équivalente, de baisse continue de la valeur de la monnaie." :

- " Il ne s'agit pas d'une augmentation ponctuelle ou à court terme du niveau général des prix ".
- "Il faut souligner que l'inflation ne concerne pas les augmentations des prix des produits individuels".
- "Il faut hésiter à qualifier d'inflation les augmentations du niveau général des prix à un taux inférieur à 1% par an."

Alors que, (Bronfenbrenner & Holzman,1963) différencient quatre de significations de l'inflation :

- Quand "trop d'argent court après trop peu de biens".
- "Augmentation de la masse monétaire ou du revenu monétaire, soit total, soit par habitant".
- "Augmentation du niveau des prix avec des caractéristiques ou des conditions supplémentaires : elle est incomplètement anticipée ; elle conduit (via des augmentations de coûts) à d'autres augmentations ; elle n'augmente pas l'emploi et la production réelle ; elle est plus rapide qu'un certain taux " sûr " ; elle surgit " du côté de la monnaie " ; elle est mesurée par les prix nets d'impôts indirects et de subventions ; et/ou elle est « irréversible ».
- "Réduction de la valeur externe de la monnaie, mesurée par le prix de l'or, par le taux de change ou indiquée par une demande excédentaire d'or ou de devises aux taux officiels".

2. Types & mesures de l'inflation

De manière générale, l'inflation peut être regroupée en quatre types, en fonction **de son ampleur** :

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- **L'inflation rampante** : Elle se produit lorsque la hausse des prix est très lente. Une hausse annuelle soutenue
Une hausse annuelle soutenue des prix de moins de 3 % par an entre dans cette catégorie. Une telle hausse des prix est considérée comme sûre et essentielle à la croissance économique.
- **L'inflation ambulante** : On parle d'inflation ambulante lorsque les prix augmentent modérément et que le taux d'inflation annuel est à un seul chiffre. Cela se produit lorsque le taux d'augmentation des prix se situe dans une fourchette intermédiaire de 3 à moins de 10 %.
Une inflation de ce taux est un signal d'alarme pour le gouvernement qui doit la contrôler avant qu'elle ne se transforme en inflation galopante.
- **L'inflation galopante** : Lorsque les prix augmentent rapidement au rythme de 10 à 20 % par an, on parle d'inflation galopante.
Ce type d'inflation a des effets négatifs considérables sur les pauvres et la classe moyenne. Son contrôle nécessite des mesures monétaires et fiscales fortes.
- **L'hyperinflation** : L'hyperinflation se produit lorsque les prix augmentent très rapidement à des taux à deux ou trois chiffres.
On peut en arriver à une situation où le taux d'inflation n'est plus mesurable et absolument incontrôlable.
Les prix peuvent augmenter plusieurs fois par jour. Une telle situation entraîne un effondrement total du système monétaire en raison de la baisse continue du pouvoir d'achat de la monnaie.

Nous pouvons même répartir l'inflation en fonction de la **volatilité de ses composantes** :

- **Inflation globale** (*Headline inflation*) : C'est l'inflation totale dans une économie. Le chiffre de l'inflation globale comprend l'inflation d'un panier de biens incluant des produits de base comme les denrées alimentaires et l'énergie qui ont tendance à être plus volatile et sujet à des pics d'inflation. Elle est différente ²de l'inflation sous-jacente ou de base, qui exclut les prix des aliments et de l'énergie lors du calcul de l'inflation.
- **Inflation sous-jacente** (*Core inflation*) : Le taux d'inflation de base est la variation des prix des biens et services dans une économie hors les produits alimentaires et énergétiques. Cette exclusion s'explique par la volatilité de ces composantes. Ils changent si rapidement qu'ils peuvent fausser la lecture précise des tendances sous-jacentes de l'inflation.

Mesures de l'inflation en Tunisie :

Il existe trois approches pour mesurer l'inflation. Ces approches sont l'indice de prix à la consommation (IPC), l'indice des prix à la production (IPP) et le déflateur implicite du produit national brut (PNB).

Les deux approches du IPC et IPP sont considérées comme des mesures directes de l'inflation. Parmi la variété d'indices de prix qui tentent de mesurer l'inflation, l'IPC est généralement la meilleure mesure utilisée dans la majorité des pays.

Cet indice des prix à la consommation est une mesure de l'évolution du niveau moyen des prix des biens et services acquis, achetés ou payés par les ménages et pondérés par leur part dans la consommation moyenne.

Les économistes ont construit un indice des prix à la consommation pour mesurer ces variations observées, vu qu'il n'est pas possible d'observer la variation des prix de tous les biens dans l'économie.

Pour la détermination de l'IPC, les instituts de statistiques gouvernementales (INS en Tunisie) construisent un échantillon de biens et services finaux représentatifs ("panier de la ménagère") pondérés par leur poids dans la consommation. L'enregistrement des prix se fait par enquête et échantillonnage permanents.

Le principal défi dans le calcul de l'indice est l'apparition de nouveaux produits ou services du au progrès technologique, ou par l'évolution des produits existant ou même la disparition de certain produit. Pour tenir compte de ces éventuels changements certains types de produits de l'échantillon doivent être actualisé tous les ans

Cet indice est construit en deux étapes. La première étape est la construction d'un indice de prix pour chaque type de produit spécifique de l'échantillon sur tout le territoire.

Ensuite ces indices sont agrégés par catégories de plus en plus large jusqu'à l'indice d'ensemble en les pondérant suivant la structure de consommation des ménages, elle-même mise à jour chaque année.

L'indice est utilisé pour mesurer le taux de l'inflation sur une période donnée et donc l'évolution de la valeur de la monnaie.

En Tunisie, l'inflation est évaluée au moyen de l'indice des prix à la consommation établie par l'institut nationale des statistiques et employée comme indicateur de l'inflation.

L'INS publie mensuellement les résultats de l'IPC en utilisant la classification des fonctions de consommation des ménages selon la nomenclature internationale "COICOP" (*Classification of*

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Individual Consumption by Purpose) qui comporte 12 fonctions de consommation finale des ménages².

Selon le papier publié par l'INS : « **Méthodologie de l'Indice des prix à la Consommation Familiale** », l'IPC est utilisé notamment pour tracer les décisions de la Politique Monétaire et pour suivre la conjoncture économique en Tunisie.

Le taux d'inflation annuelle est mesuré selon cette formule :

$$\text{Taux d'inflation annuelle en \%} = \frac{IPC_{\text{année } t} - IPC_{\text{année } t-1}}{IPC_{\text{année } t-1}} * 100$$

Le taux d'inflation mensuelle est mesuré selon cette formule :

$$\text{Taux d'inflation mensuelle en \%} = \frac{IPC_t - IPC_{t-12}}{IPC_{t-12}} * 1$$

3. Les mécanismes économiques de l'inflation

3.1 L'inflation par la demande (« Keynésienne ») ou « demande pull » :

John Maynard Keynes (1883-1946) et al., ont mis l'accent sur l'augmentation de la demande globale comme étant la source de l'inflation et l'un de ses mécanismes internes qui ne prend pas en considération l'influence des économies étrangères.

La demande globale comprend essentiellement trois éléments : la consommation, l'investissement et les dépenses publiques.

Le risque de l'inflation persiste lorsque la valeur de la demande globale excède celle de l'offre globale au niveau du plein emploi créant ainsi un écart inflationniste.

Plus l'écart entre la demande et l'offre globales s'élargit, plus l'inflation s'accélère.

Selon Keynes et al., la demande effective et l'inflation peuvent être amortie par certaines mesures (seules ou ensemble) comme la réduction des dépenses publique par l'augmentation des impôts et le contrôle du volume de la monnaie.

Dans des conditions difficiles, comme l'hyperinflation pendant la guerre, le contrôle du volume de la monnaie ou la diminution des dépenses générales ne sont pas efficaces. Ainsi, l'augmentation de la taxe peut s'accompagner d'une action directe pour le contrôle de la demande.

² Alimentation et boissons non alcoolisés ; Boissons alcoolisés et tabac ; Articles d'habillement et articles chaussants ; Logement, eau, électricité, gaz et autres combustibles ; Ameublement, équipement ménager et entretien courant de la maison ; Santé ; Transport ; Communication ; Loisirs et culture ; Enseignement, Éducation ; Hôtellerie, cafés, restauration ; Autres biens et services.

3.2 L'inflation par la monnaie :

Selon les monétaristes (M. Friedman), la croissance masse monétaire ajustée à la croissance réelle de l'économie est considérée comme le déterminant "dominant", bien que non exclusif" de l'inflation.³

L'inflation par la monnaie stipule que la hausse du niveau général des prix résulte d'une émission monétaire trop importante. Pour Milton Friedman : « l'inflation est toujours causée par : un accroissement de la quantité de monnaie en circulation que celui du volume de la production totale ».

Cette idée se repose sur la "théorie quantitative de la monnaie" ou l'équation des échanges d'Irving Fisher ($MV=PT$).

3.3 L'inflation par les coûts :

L'inflation par les coûts est due à un déséquilibre entre l'offre et la demande provenant d'un choc du côté de l'offre suite à la hausse des coûts de production : soit l'augmentation des coûts salariaux ainsi que les prix des matières premières ou des produits de base importés (l'inflation importée suite à la dépréciation de la monnaie locale) plus rapidement que la productivité du travail. Ce type d'inflation n'est pas un phénomène nouveau et a été constaté même pendant la période médiévale. Mais il a été revu dans les 1950 et à nouveau dans les années 1970 comme la principale cause de l'inflation.

Les syndicats exercent une pression sur les employeurs pour qu'ils accordent des augmentations salariales considérables, ce qui mène par la suite à une augmentation du coût de production des produits de base.

Les salaires plus élevés incitent les travailleurs à acheter autant qu'avant malgré la hausse des prix. D'un autre côté, l'augmentation des prix incite les syndicats à exiger des salaires encore plus élevés car la hausse du niveau général des prix déprécie le pouvoir d'achat des salariés.

De cette façon, la spirale salaires-coûts s'installe sur une longue période, ce qui conduit à une inflation par les coûts.

Cette inflation peut s'accroître suite à un ajustement à la hausse des salaires pour que la hausse des prix soit compensée. Quelques secteurs de l'économie peuvent être affectés par la hausse des salaires et les coûts de productions.

Dans de nombreux cas, les produits de ces secteurs sont utilisés comme intrants pour le processus de production d'autres secteurs.

³ FRIEDMAN Milton. Inflation et système monétaire. Ed Calmann-Lévy, 1976

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Par conséquent, le coût de production des autres secteurs va augmenter et pousser à la hausse les prix de leurs produits. Ainsi, l'inflation par les salaires dans certains secteurs de l'économie peut conduire ultérieurement à la hausse des prix dans l'ensemble de l'économie.

Notamment, on note que dans une économie où les agents sont habitués à l'inflation, les anticipations de cet indicateur conduit à revendiquer des hausses salariales qui auront un impact inflationniste. De même, les producteurs qui s'attendent à devoir concéder des augmentations de salaires des employés peuvent relever leurs prix par anticipation pour préserver leurs marges. Cette équation indique qu'une augmentation de la quantité de monnaie dans l'économie provoque de façon mécanique une hausse du niveau général des prix.

3.4 L'inflation structurelle :

Le concept d'inflation structurelle est apparu dans les recherches et les discussions économiques il y a environ 40 ans. Ce phénomène est lié à l'effet des facteurs structurels sur l'inflation.

Ce type d'inflation résulte de changements dans la structure de la demande et de l'offre. Sous l'influence de ces changements certaines secteurs connaîtront une augmentation de la demande de leurs produits, tandis que pour d'autres, cette demande diminuera.

Si les prix et les salaires dans les secteurs qui réduisent leur production sont inflexibles par rapport à cette réduction, tandis que les prix et les salaires dans les secteurs qui augmentent leur production augmentent, alors le niveau global des prix et des salaires dans l'économie augmentera. Le phénomène évoqué s'accroît lorsque l'offre sera rigide et ne pourra pas s'adapter immédiatement aux changements en cours.

Ainsi, l'inflation structurelle survient lorsque les producteurs ne peuvent pas adapter leur structure de production de manière efficace en réponse aux changements de la structure de l'économie. Ces changements peuvent concerner :

- La demande du produit,
- Les innovations des technologies de production,
- La concurrence à laquelle les producteurs sont confrontés (Barro,1995).

Les changements dans la structure de l'économie entraînent des déficiences stratégiques et l'apparition de ce qu'on appelle goulot d'étranglement dans les canaux d'approvisionnement.

Si l'offre d'un bien quelconque augmente soudainement constituant un tel goulot d'étranglement, son prix sera également plus élevé, et cette augmentation sera transférée aux prix de nombreux autres produits.

En Tunisie, l'inflation des raisons structurelles liées à l'économie parallèle qui alimente la demande globale même en présence de contraintes monétaires par la banque centrale.

3.5 L'inflation liée aux anticipations des agents économiques :

L'inflation peut elle-même contribuer à une inflation supplémentaire si les agents économiques s'y attendent.

En effet, les attentes rationnelles stipulent simplement qu'en anticipant l'inflation future face à une augmentation de la masse monétaire, le public agira de la manière la plus bénéfique pour lui. Ainsi, les travailleurs demanderont des salaires plus élevés en s'attendant à une augmentation de la demande de biens de consommation et les entreprises augmentent les salaires mais aussi les prix.

Lorsque l'augmentation perçue de la masse monétaire se réalise, le niveau de la productivité et l'emploi augmentent. Mais cette hausse est contrebalancée par une augmentation des salaires et des prix et l'économie devient de plus en plus inflationniste.

Selon Case et Fair (2007) dans leur livre intitulé "*Principles of Economics*" : les anticipations peuvent conduire à une inertie qui rend difficile l'arrêt d'une spirale inflationniste.

Plusieurs mesures peuvent briser ce cercle vicieux. Par exemple, une limitation temporaire des hausses des salaires, une réduction du déficit budgétaire ou d'autres signaux envoyés au marché pour l'inciter à réduire l'inflation.

Il est intéressant de noter que ces attentes peuvent renforcer des idées erronées. Supposons par exemple que le déficit budgétaire ait peu de rapport avec l'inflation, mais que les gens pensent qu'il est très important. En raison de ces idées erronées, le déficit budgétaire devient corrélé à l'inflation car les entreprises augmenteront leurs prix en cas de déficit budgétaire (en anticipant une inflation). Ainsi, les croyances erronées peuvent devenir auto-confirmables. (Erronées dans le sens où si personne n'avait eu cette croyance, l'inflation n'aurait pas augmenté si le déficit budgétaire avait augmenté (hypothèse). Ainsi, non seulement les attentes sont importantes pour l'inflation, mais aussi ceux qui contrôlent la croyance des gens sur les causes de l'inflation. En fin de compte, la bataille pour l'esprit des gens, les théories auxquelles ils croient, devient alors importante pour combattre l'inflation.

Un autre élément à prendre en compte est que si les attentes sont rétrospectives, c'est-à-dire qu'elles sont adaptatives, l'inflation peut être plus difficile à vaincre, car les gens ne croient pas nécessairement que les mesures prises par le gouvernement auront un impact important. Ils croient que ce qui s'est produit dans le passé se reproduira, presque indépendamment des actions politiques d'aujourd'hui. La formation d'attentes rationnelles prospectives, d'autre part, pourrait rendre la politique plus efficace si le gouvernement énonce une politique qui est suivie d'une action crédible. Pour vaincre l'inflation, il est donc important de créer l'image d'une rupture

radicale avec le passé afin que l'inflation par inertie adaptative ne se poursuive pas. Ces changements radicaux pourraient être la formation d'un gouvernement de coalition nationale ou simplement le changement du parti au pouvoir (par exemple, en Suède).

4. Les déterminants de l'inflation

Au cours des dernières décennies, différentes études académiques ont porté sur les déterminants de l'inflation dans les différents pays.

Les variables déterminantes de l'inflation selon les chercheurs dans bon nombre de ces pays sont : le taux de change, les importations & les exportations, les emprunts publics, la masse monétaire, le taux d'intérêt, l'écart de production, salaires, prix du pétrole brut, déficit fiscal et produit intérieur brut (PIB).

Kia (2006) a catégorisé un bon nombre de ces variables en deux facteurs : les facteurs internes et les facteurs externes.

Les facteurs internes représentent les activités de l'économie nationale qui influencent le taux de l'inflation ou les facteurs qui déplacent la courbe de demande globale vers la droite comme le taux de change nominal, la masse monétaire, les déficits et le financement de la dette.

Les facteurs externes sont les activités d'autres pays qui provoquent une augmentation de l'inflation.

Ces facteurs comprennent : le taux d'intérêt étranger, le prix des importations, le commerce, les sanctions économiques et la guerre.

De même, les déterminants de l'inflation peuvent être classés selon deux écoles : Monétaristes (Milton Friedman, 1970) et structuralistes (Adu George et Marbuah 2011).

Les monétaristes associent l'inflation à la croissance monétaire et proposent des mesures monétaires pour la contrôler.

En revanche, les structuralistes supposent que les facteurs monétaires ne sont pas les seuls à causer l'inflation et affirment que la plupart des mesures proposées par les monétaristes pour contrôler l'inflation ne peuvent être efficaces qu'à long terme.

Les structuralistes ont reconnu notamment l'importance des volontés politiques, telles que les réformes fiscales, dans la lutte contre l'inflation. Les effets de ces facteurs structurels sont étroitement liés à l'inflation par les coûts (Parkin, 1991 pg 9).

Mhamdi (2015) suggère que les déterminants fondamentaux de l'inflation en Tunisie sont essentiellement les revenus de la population, la productivité du travail, l'influence du taux de change et l'inertie dans le processus d'inflation.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Boukairine (2020) confirme dans une étude récente qu'à court terme, l'inflation en Tunisie est déterminée par l'évolution des prêts et de la dette extérieure. Les résultats de l'étude soulignent que les prêts et la croissance du PIB ont un impact significatif sur l'inflation à long terme au niveau de 5% tandis que la dette extérieure affecte l'inflation avec un niveau de signification de 10 %.

D'après Papi et Lim (1997), une exportation excessive peut entraîner à la réduction des produits de base et donc à une augmentation des prix. De l'autre côté, l'augmentation des dépenses d'importation contribue à la diminution des dépenses en biens domestiques et donc à l'inflation des médicaments.

Campa et Goldberg (2002) ont conclu qu'une baisse du taux de change d'une nation entraîne la croissance des prix à l'importation et la dépréciation des prix à l'exportation.

En ce qui concerne les taux d'intérêt, il existe une forte relation entre l'inflation et les taux d'intérêt et les monétaristes utilisent souvent les taux d'intérêt pour contrôler l'inflation. D'un point de vue empirique, la relation entre le taux d'intérêt et l'inflation a été

Fréquemment explorée par l'hypothèse de Fisher via la cointégration. Autrement dit, il existe une relation à long terme entre le taux d'intérêt nominal et l'inflation attendue. Le taux d'intérêt nominal est constitué du taux réel plus un taux d'inflation attendu.

Selon l'hypothèse de Fisher, le taux réel est constant dans le temps ; par conséquent, le taux nominal doit changer - point pour point - lorsque l'inflation attendue augmente ou diminue⁴⁷.

Des études empiriques ont apporté leur soutien à l'hypothèse de Fisher (Gul et Acikalin, 2007 et Ozean et Ari ,2015). Cela implique que le taux d'intérêt a une influence directe sur l'inflation. En revanche, peu d'études ont argumenté contre la théorie de l'hypothèse de Fisher. Parmi les études qui se sont opposées à la théorie, il existe un consensus sur le fait que les rejets de la théorie de Fisher ne sont pas justifiés (étaient principalement dus à des problèmes économétriques et à la conduite des politiques monétaires).

Les "réserves étrangères" sont également un facteur important de l'inflation. Une étude précédente de Lin et Wang (2005) a établi que le taux d'inflation augmentait avec l'expansion des réserves de change.

Quant au PIB, une étude empirique réalisée par Dewan et Hussein (2001) a conclu qu'une corrélation positive lie l'inflation au produit intérieur brut. En effet, dans la mesure où une demande sur le marché augmente, le produit intérieur brut augmente. Parallèlement, une demande importante conduit à des biens plus chers et donc à l'inflation.

Section 2 : Les techniques de prévisions de l'inflation

La prévision consiste à prédire diverses variables sur la base de données passées et présentes. Les principales méthodes de prévision en économie sont le jugement d'expert, les indicateurs avancés, les enquêtes, les équations économétriques, les modèles de séries chronologiques ainsi que les techniques de Machine Learning.

1. Revue de la littérature académique relative aux outils de prévision de l'inflation

Étant donné qu'elle est d'une importance capitale tant pour les agents économiques que pour les décideurs, la prévision de l'inflation attire davantage l'attention, et les études et les recherches sont de plus en plus nombreuses dans la littérature dans les économies développées et émergentes.

Dans la littérature, la qualité des prévisions de l'inflation dépend généralement de l'horizon d'analyse mais aussi du type de modèle utilisé.

A ce titre, divers techniques et modèles de prévision sont généralement expérimentés à savoir :

- (i) **Les modèles univariés (ARIMA, Random Walk, etc) ,**
- (ii) **Les modèles multivariés de type VAR et ses variantes,**
- (iii) **Les modèles factoriels,**
- (iv) **D'autres formes de modèles (courbes de Phillips, modèles à facteurs dynamiques, modèles d'Equilibre Général Dynamique Stochastique (DSGE), etc) et**
- (v) **Les techniques alternatives.**

Les premiers modèles largement utilisés étaient basés sur la « courbe de Phillips » pour la prévision de l'inflation et souvent utilisée dans le cadre de modèles DSGE.

Dans l'une des premières études, Stock et Watson (1999) ont utilisé un modèle standard de courbe de Phillips pour prévoir l'inflation américaine.

La qualité prédictive de ces modèles dépend de nombreux facteurs dont le principal est la conjoncture économique. De ce fait, l'estimation d'une « *courbe de Phillips* » peut être utile à certaines périodes et ne pas l'être à d'autres. McKnight et al. (2020) ont constaté qu'un nouveau cadre de « *la nouvelle courbe de Philips keynésienne* » surpasse les modèles de référence classiques de prévision de l'inflation

Quant aux modèles univariés, ils sont les plus simples et les plus basiques en termes de modélisation. Parmi ces modèles on distingue : les modèles ARIMA et les modèles de marche

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

aléatoire. Généralement ces modèles de prévision sont utilisés comme benchmark pour d'autres plus sophistiqués.

Selon Stock et Watson (2006), ces approches sont très efficaces pour les prévisions à court et à très court terme.

Toutefois, parmi les limites de ces modèles est le fait qu'ils ignorent le cadre macroéconomique dont évolue la variable économique. Ainsi, c'est pour cette raison les décideurs font appel aux modèles multivariés. Les modèles VARs simples et ses variantes sont généralement les plus utilisés dans la littérature. Notamment les VARs bayésien et les VARs augmenté de facteurs.

Ces modèles permettent de prendre en compte les relations de causalité, notamment les endogénéités qui existent entre plusieurs variables macroéconomiques (Canova, 2002) et représentent un outil supplémentaire d'aide à la décision pour les conjoncturistes et les décideurs de la politique monétaire dans les banques centrales.

Lajmi et El Khadhraoui (2013) ont développé un modèle de prévision de l'inflation à moyen terme pour la Tunisie qui est fondé sur la théorie néo-keynésienne. Ce modèle était inspiré du GPM (Global Projection model) construit par le FMI, et ajusté aux spécificités de l'économie tunisienne.

Il s'agit d'un modèle semi-structurel basé sur des équations simultanées qui incluent essentiellement quatre variables macroéconomiques à savoir : l'inflation, le taux d'intérêt à court terme (TMM), le taux de croissance du taux de change nominal, le taux de croissance du PIB réel.

Le modèle permet d'étudier les dynamiques de l'offre et de la demande agrégées, du taux de change réel et du taux d'intérêt nominal.

Certaines études menées par Forni et al. (2003) ont testé la performance des modèles factoriels, avec un grand nombre de variables macroéconomiques pour la prévision de l'inflation dans la zone euro. Ces modèles factoriels multivariés surperforment pour des horizons à long terme les modèles autorégressifs univariés.

Plus récemment, Kotchoni et al. (2019) ont comparé les performances prédictives d'un ensemble de modèles factoriels avec des modèles autorégressifs pour les Etats-Unis sur la période de 1960 à 2014. Et ils ont constaté que la performance de ces modèles n'est pas stable dans le temps.

Cependant, les modèles de prévision riches en variables macroéconomiques semblent battre les modèles autorégressifs dans les périodes de récession à des horizons plus longs.

Les modèles DSGE qui sont plus complexes ont également été utilisés pour prévoir l'inflation dans les économies émergentes et avancées (Pichler, 2008 pour l'USA ; Iversen et al., 2016 pour la Suède).

Les techniques alternatives de prévision de l'inflation vont être examinées en détail dans le deuxième chapitre de ce travail.

2. Dispositifs de prévision de l'inflation dans les banques centrales

Il existe une grande similitude entre les banques centrales dans les mécanismes de base des prévisions.

Cependant, il existe des différences dans l'importance accordée aux prévisions fondées sur des modèles par rapport aux prévisions discrétionnaires et à celles fondées sur l'opinion d'experts.

Les banques ayant des objectifs de stabilité de prix ont eu tendance à privilégier les approches basées sur des modèles dans le cadre d'une stratégie visant à garantir la transparence.

Pour les décisions de politique monétaire, les prévisions d'inflation et de croissance de la production globale sont les candidats évidents, mais les décideurs peuvent également vouloir examiner les prévisions de variables telles que l'investissement, les dépenses de consommation, les salaires ainsi que les projections concernant les perspectives mondiales. Cela dit, cette liste est rarement exhaustive, tout simplement parce que la construction d'une prévision pour, par exemple, l'inflation peut nécessiter une prévision d'autres variables telles que la productivité.

Ces prévisions intermédiaires peuvent être ou ne pas être présentées aux décideurs politiques, mais elles sont souvent fournies implicitement lors de la discussion de l'environnement entourant une prévision.

Une deuxième raison pour laquelle un nombre relativement important de variables doit être prévu est qu'un conseiller politique doit fournir une explication des prévisions.

Par exemple, une prévision de la demande globale peut devoir être séparée en deux composantes de la consommation et de l'investissement, car l'environnement économique actuel peut suggérer que ceux-ci sont susceptibles d'évoluer dans des directions différentes.

Les banques centrales font appel généralement à cinq types de modèles pour les prévisions, à savoir :

- **Le modèle "de base" : Core model** : La plupart des institutions chargées de l'élaboration de la politique monétaire disposent d'un modèle "de base" qui résume les principales relations au sein de la macroéconomie et constitue le modèle de référence pour les prévisions et l'évaluation des politiques à moyen terme.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Ces modèles contiennent généralement environ 30 à 50 équations stochastiques et déterminent 100 à 200 autres variables par le biais d'identités. La philosophie de modélisation implique souvent la sélection d'un ensemble de relations à long terme, telles qu'une part de travail et une constante, une fonction de production et un taux de change réel à long terme constant.

L'importance d'un modèle de base dépend en grande partie du mélange relatif d'analyse de scénarios et de prévisions dans la prise de décisions politiques.

Les modèles de base bien conçus peuvent présenter certaines caractéristiques spécifiques qui peuvent être utiles à la formulation de la politique monétaire. L'une d'entre elles est une solution en régime permanent qui peut être consultée pour visualiser les conséquences à long terme d'une action politique.

- **Petits modèles prospectifs :** Ces modèles incarnent ce que l'on appelle parfois le modèle de la banque centrale (voir McCallum 1999 et Clarida, Gali et Gertler, 1999). Ils contiennent une courbe dite IS qui relie la croissance du produit intérieur brut (PIB) à des facteurs tels que les taux d'intérêt, l'inflation attendue, la croissance passée et attendue de la production
Ils contiennent également une courbe de Phillips qui relie l'inflation à l'inflation passée et attendue, ainsi que l'écart de la production par rapport aux niveaux de "capacité".
- **Auto-régressions vectorielles :** Les modèles autorégressives vectorielle (VAR) sont utilisés principalement pour explorer des questions spécifiques telles que le rôle des agrégats monétaires dans la prévision de l'inflation et de la croissance de la production. Ces modèles s'avèrent efficaces pour les prévisions de court terme.
- **Modèles de régression à une équation :** Un exemple de modèles de régression à une équation sont les modèles de la courbe de Phillips et les relations résumant le lien entre le taux de change et les prix des produits de base) dans les pays en développement. Les principaux avantages de ces modèles sont leur simplicité et le fait qu'ils peuvent être facilement utilisés pour calculer des prévisions conditionnelles à une série d'alternatives pour les variables explicatives. Dans certains cas, les prévisions conditionnelles peuvent être utilisées comme des vérifications croisées des prévisions du modèle de base, et parfois l'objectif est de donner aux décideurs une idée des relations à long terme dans l'économie.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- **Modèles d'optimisation dynamique** : Ces modèles sont nécessaires pour comprendre les conséquences économiques probables d'un changement structurel particulier ou d'un choc atypique.

Ils produisent rarement des prévisions directement, mais peuvent être un ingrédient d'une prévision et sont parfois importants pour comprendre les prévisions.

Les modèles de cette catégorie vont des modèles d'équilibre général stochastiques dynamiques aux modèles d'évaluation des actifs.

- **Des approches alternatives** : les approches basées sur les modèles de Machine Learning entrent récemment dans la boîte à outils de prévision pour certaines banques centrales.

2.1 Prévision de l'inflation par la BCT

Pour une politique monétaire proactive, moderne et développée, la BCT assure une prévision de l'inflation et de différents indicateurs économiques à différents horizons à travers plusieurs modèles :

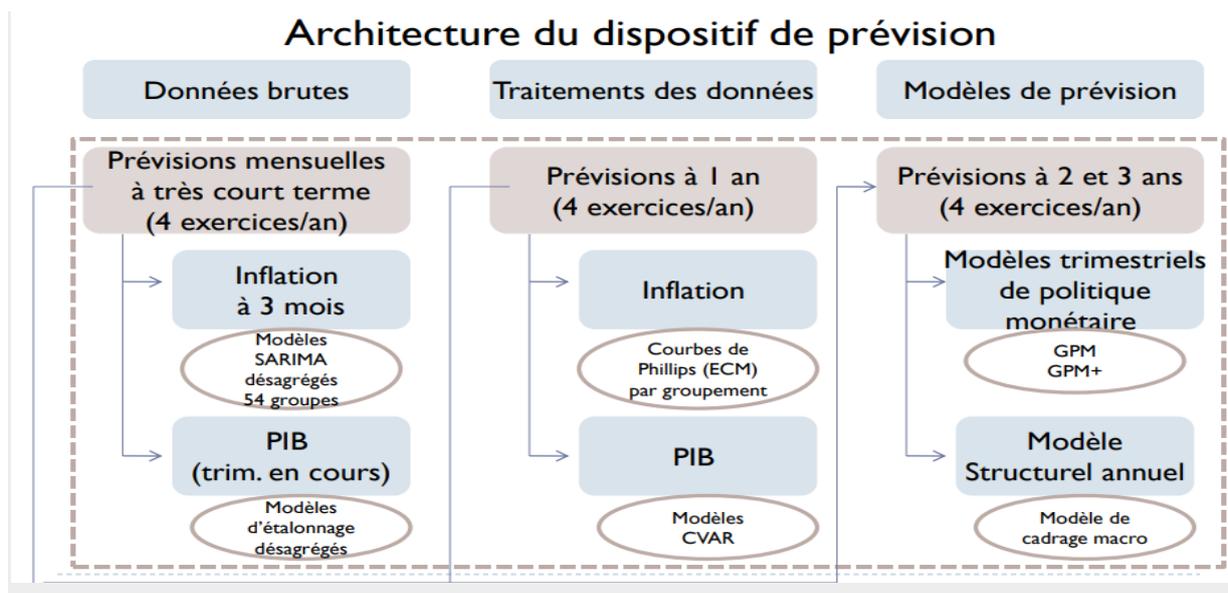


Figure 1. Architecture du dispositif de prévision de la BCT.

Source : Présentation du projet de jumelage entre la BCT et la Banque de France, 2013

La prévision à court terme de l'inflation :

La prévision à court terme (entre 3, 6 et 12 mois) de l'inflation servira de point de départ aux prévisions de moyen terme. Pour ce faire, les prévisionnistes font appel à une panoplie de modèles économétriques : Le modèle ARIMA, Les modèles à correction d'erreur, Les modèles

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

à facteurs dynamiques, Le modèle Reg-ARIMA (pour traiter les effets spécifiques non linéaires affectant les différents indices).

Les étapes de prévision de l'inflation à CT :

- 1) Collecte des données nécessaires à la prévision : Produits alimentaires (transformés, libre et administrés), produits manufacturés (libres, administrés), services libres et administrés et des données internationales (prix internationaux, cotation EUR/USD, Prix du BRENT,etc) ;
- 2) Traitement de la saisonnalité des variables à l'aide du logiciel DEMETRA ;
- 3) Des programmes de calage : l'ensemble des processus d'ajustements des variables d'entrée et des paramètres du modèle ;
- 4) Application du modèle de prévision ;
- 5) Le reporting de la prévision.

Pour diagnostiquer l'évolution de la conjoncture dans le secteur et des évolutions monétaires, les responsables de la politique monétaire utilisent trois modèles économétriques de prévisions à CT :

- **MPICT:** Un modèle trimestriel utilisé pour l'estimation la croissance trimestrielle du PIB en fonction d'un certain nombre d'indicateurs conjoncturels .
- **DFM:** Modèle à facteurs dynamiques utilisé pour estimer l'évolution de l'indice du prix à la consommation (IPC) sur un horizon de 1 à 2 trimestres.
- **CVAR:** Un modèle économétrique utilisé pour mettre en relation la croissance trimestrielle du PIB avec l'évolution d'une ou deux variables tels que les exportations ou les importations (sur un horizon de 1 à 4 trimestres).

La modélisation et la prévision à moyen terme :

La prévision de l'évolution future de l'inflation sur le moyen terme est basée sur les prévisions de CT pour prendre les mesures nécessaires et agir au temps opportun sur les instruments de la politique monétaire. Pour le faire, le service fait appel à un modèle économétrique inspiré du modèle GPM (global projection model) du FMI, spécifique à l'économie tunisienne (4 fois par an) dont la structure est basée sur :

- Les 4 principales équations de comportement : Demande, Offre, Taux d'intérêt et Taux de change) et
- Les anticipations des agents économiques (backward & forward looking).

2.2 Prédiction de l'inflation dans la banque de Suisse

Les décideurs de la politique monétaire de la Banque Nationale de Suisse se basent sur la prévision de l'inflation pour élaborer la stratégie future.

Pour la Banque nationale de Suisse, la prévision de l'inflation est élaborée à partir d'un processus de pondération de plusieurs prédictions par différents types de modèles. Les prédictions sont basées sur les résultats de simulations de modèles économétriques et de l'analyse de l'évolution de différents indicateurs économiques.

Le modèle global de prévision utilisé par la Banque Nationale de Suisse est un modèle macroéconomique qui se compose de modèles économétriques structurels (de moyenne et petite taille), modèle vectoriels autorégressifs et modèle de demande pour l'agrégat monétaire M3.

2.3 Prédiction de l'inflation dans la Banque d'Angleterre Royaume-Uni

Le comité de la politique monétaire de la banque d'Angleterre assure les prévisions d'inflation et de production trimestriellement dans le rapport sur l'inflation de la Banque depuis février 1993.

Ces prévisions sont censées résumer le point de vue des membres du Comité de la politique monétaire.

Le processus actuel de prévision de la Banque d'Angleterre et les " fan charts " d'inflation et de production qui en résultent constituent une tentative explicite de transposer l'incertitude du décideur quant aux différentes hypothèses économiques sur une distribution des résultats futurs via une combinaison de modèles et de jugement.

À la suite de ces discussions les prévisionnistes préparent les trajectoires centrales (les plus probables) ainsi que des distributions de prévisions construites de manière à refléter aussi précisément que possible l'évaluation par le Comité de politique monétaire des risques relatifs (asymétrie) et l'incertitude globale (variabilité).

Ces distributions prévisionnelles pourraient être révisées à la suite de réunions ultérieures.

La Banque d'Angleterre dispose d'une série de modèles et a rendu publiques les descriptions des différents modèles (Banque d'Angleterre).

Le modèle macroéconomique de base, appelé MM (Macro Model), fait intervenir une vingtaine d'équations et 130 variables au total.

A certains égards, le modèle MM peut être considéré comme ayant été construit à partir d'une perspective "ascendante" (équation par équation). La structure sous-jacente du MM implique la spécification :

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

(1) d'un équilibre à long terme des variables réelles qui est indépendant du niveau des prix et qui ne présente pas d'arbitrage d'inflation à long terme ;

(2) un équilibre des variables nominales déterminé par une cible d'inflation et une règle de rétroaction pour le court terme.

(3) un ajustement lent aux chocs en raison des rigidités réelles et nominales.

Les services de la Banque d'Angleterre ont également utilisé divers modèles de courbe de Phillips à équation unique pour étudier la relation entre l'inflation et des variables de l'économie réelle, et pour simuler les implications pour l'inflation de différentes du taux de chômage.

Les modèles VAR, ces modèles sont utilisés pour vérifier les prévisions d'inflation produites par le modèle principal.

La banque d'Angleterre fait appel récemment aux techniques de Machine Learning (KNN, Random Forest, etc) pour la prévision de l'inflation.

2.4 La prévision de l'inflation dans la Réserve fédérale américaine

La politique monétaire des États-Unis est définie par le comité fédéral de l'open market (FOMC) qui prépare des prévisions sur l'activité économique américaine et internationale avant chacune des huit réunions du FOMC qui ont lieu chaque année dans le cadre du briefing du président de sa banque avant une réunion du FOMC.

Les diverses prévisions du Conseil d'administration et des Fed régionales ne sont rendues publiques que plusieurs années après une réunion du FOMC.

Toutefois, un résumé des perspectives des responsables de la politique monétaire est contenu dans les prévisions du PIB, de l'inflation et du chômage soumis au Congrès deux fois chaque année.

Les informations dont disposent les responsables de la politique monétaire du FOMC proviennent d'un certain nombre de sources.

Premièrement, chaque Fed régionale recueille des informations anecdotiques sur les conditions économiques actuelles dans son district par le biais des rapports des directeurs de la banque et de ses succursales et d'entretiens avec des contacts commerciaux clés, des économistes, des experts du marché et d'autres sources.

Le livre beige (« Beige book ») résume ces informations. En outre, le conseil reçoit des informations directement de divers conseils consultatifs qui peuvent fournir une évaluation des développements économiques récents.

Deuxièmement, le personnel du Conseil des gouverneurs produit plusieurs documents pour les réunions du FOMC.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

L'un d'eux est intitulé "Conditions économiques et financières actuelles" et est communément appelé Greenbook.

Le livre vert ou Greenbook présente l'évaluation par les services du FOMC des évolutions récentes de la macroéconomie nationale ainsi les prévisions trimestrielles ponctuelles pour les principaux agrégats de l'économie nationale, tels que les grandes composantes de l'inflation, PIB, le chômage, et les salaires.

L'horizon de prévision du livre vert peut aller jusqu'à deux ans, bien qu'il soit parfois aussi court qu'un an mais il est parfois aussi court que six trimestres.

Un autre document, le Bluebook, contient des simulations de modèles pour examiner des stratégies alternatives de la politique monétaire sur une période plus longue, souvent jusqu'à cinq ans. Ces simulations sont présentées formellement au moins deux fois par an.

Après une certaine itération, la prévision "consensuelle" est publiée dans le livre vert.

Les données de séries chronologiques à haute fréquence (mensuelles, hebdomadaires) sont utilisées pour ajuster les prévisions à court terme en fournissant de meilleures estimations des conditions initiales.

Le conseil maintient un modèle national de base, connu sous le nom de modèle FRB/US (Federal Reserve Board's). Ce modèle contient une quarantaine d'équations.

Il se distingue de son prédécesseur principalement par la séparation explicite de la macrodynamique du secteur non financier.

En particulier, la plupart des variables du secteur non financier sont supposées évoluer progressivement afin d'éliminer les déséquilibres passés (écarts entre les niveaux réels et les niveaux souhaités) et répondent également la trajectoire que l'équilibre devrait suivre à l'avenir. Le modèle FRB/US est utilisé en tant qu'entrée du système de prévision du Greenbook, principalement en tant qu'outil de prévision de l'inflation.

La FED fait appel récemment aux techniques de Machine Learning (Deep learning) pour la prévision de l'inflation en se basant sur une large base de données.

3. Les méthodes conventionnelles : Revue de la littérature

Dans cette section, nous présentons les modèles économétriques couramment utilisés pour la prévision de l'inflation pour un horizon de court terme. L'objectif est de présenter la théorie sous-jacente à ces modèles qui vont être références pour les modèles d'apprentissage statistique développé dans l'application empirique dans le deuxième chapitre.

3.1 Les modèles univariés ARIMA

La moyenne mobile intégrée autorégressive (ARIMA) est un modèle de série temporelle univarié et représente une généralisation du modèle de moyenne mobile autorégressive (ARMA)⁴. Les modèles ARIMA ont été développés en 1976 par les deux statisticiens George Box et Gwilym Jenkins. Ces modèles ont souvent été désignés sous le nom de procédures du modèle Box-Jenkins. Les modèles ARIMA ont été largement utilisés pour la prévision de l'inflation, et ils ont donné de bons résultats par rapport à d'autres modèles de prévision de l'inflation (Hafer et Hein 1990, Stock et Watson 2007).

Ces méthodes de prévision des séries temporelles sont essentiellement agnostiques car ils ne sont dérivés d'aucune théorie économique.

Contrairement à d'autres modèles, elles ne supposent pas la connaissance d'un modèle économique ou de relations structurelles.

Ce type de modèle est basé uniquement sur la dynamique intrinsèque de l'inflation seulement, et ne prend pas en considération les interactions qui peuvent exister entre l'inflation et d'autres variables macroéconomiques

$(X_t)_{t \in \mathbb{N}}$ est un processus ARIMA d'ordre (p, d, q) , noté ARIMA (p, d, q) si :

$$\Phi(L) \nabla^d X_t = \Theta(L) \varepsilon_t$$

Où

- ε_t : Est un bruit blanc gaussien
- L : Est un opérateur de retard
- $\nabla^d = (I - L)^d$
- $\Phi(L) = I - \varphi_1 L - \dots - \varphi_p L^p$ où $(\varphi_1, \dots, \varphi_p) \in \mathcal{R}^p$ et $\varphi_p \neq 0$
- $(I - L)^d X_t$ Est équivalent asymptotiquement à un processus ARMA (p, q) .
- $\Theta(L) = I + \theta_1 L + \dots + \theta_q L^q$ où $\theta_q \neq 0$
- Le processus $(X_t)_{t \in \mathbb{N}}$ N'est pas stationnaire

Les paramètres p , d et q sont respectivement :

- Le processus autorégressif d'ordre p : AR(p),
- Un ordre d'intégration d'ordre d : I(d) et
- Le processus de moyenne mobile (MA) d'ordre q : MA(q).

⁴ Les modèles ARMA ne traitent que les séries stationnaires alors que les modèles ARIMA permettent de traiter les séries temporelles non stationnaires.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

La modélisation est exprimée en termes de valeurs passées de la variable à prédire (la composante autorégressive (AR)), les valeurs actuelles et retardées du terme d'erreur (la composante moyenne mobile (MA)) ainsi qu'une composante intégrée (qui fait référence au nombre de fois qu'une série est différenciée pour induire la stationnarité).

Le processus de modélisation et la prévision à l'aide de modèles ARIMA comportent cinq phases :

- (i) L'identification,
- (ii) L'estimation,
- (iii) Un diagnostic,
- (iv) La sélection du modèle et la prévision.

La meilleure prévision linéaire (au temps t) d'un modèle ARIMA(p,d,q) est :

$$\widehat{X}_t = E[(X_{t+k}|F_t)] = \sum_{i=1}^p \widetilde{\varphi}_i \widehat{X}_t (k-i) + \sum_{i=k}^q \theta_i \widehat{\varepsilon}_{t+k-i}$$

$\widetilde{\varphi}_i$ Sont les coefficients du polynôme $\varphi(B)(1-B)^d$ (dans le cas d'un modèle ARMA $\widetilde{\varphi}_i = \varphi_i$)

Il existe deux formes de modèle ARIMA :

- Les modèles non saisonniers (ARIMA) et
- Les modèles saisonniers à moyenne mobile intégrée autorégressive (SARIMA).

Un **modèle ARIMA saisonnier** (SARIMA) est utilisé lorsque les données de la série temporelle présentent des variations saisonnières. Pour les prévisions de fréquences semestrielles, trimestrielles ou mensuelles on fait appel généralement aux modèles SARIMA.

Alors que le modèle ARIMA non saisonnier est utilisé lorsqu'il n'y a pas de saisonnalité.

Le modèle SARIMA est donné par la notation suivante : $ARIMA(p, d, q)(P, D, Q)m$ où (p, d, q) sont les paramètres ARIMA.

La notation : $(P, D, Q)m$ correspond aux paramètres saisonniers supplémentaires :

- P est le nombre de termes autorégressifs saisonniers,
- D est le nombre de termes de différence saisonnière,
- Q est le nombre de termes de moyenne mobile saisonnière et
- m correspond à la fréquence de période saisonnière.

Les paramètres (p,d,q) sont déterminés à l'aide de la fonction d'autocorrélation (ACF)⁵, des fonctions d'autocorrélation partielle (PACF) et des tests de stationnarité.

La précision de chaque modèle est évaluée à l'aide de l'erreur quadratique moyenne (MSE). Nous choisissons MSE comme métrique à minimiser par chaque modèle car, par rapport à l'erreur absolue moyenne (MAE), le MSE pénalise davantage les grands écarts.

Cependant, après avoir ajusté chaque modèle pour obtenir le MSE la plus faible et pour faciliter l'interprétation, afin de comparer la précision de la prévision entre les modèles dans l'échantillon de test, nous rapportons l'erreur quadratique moyenne (RMSE).

Fritzer et al (2002) constatent les modèles univariés surperforment les modèles multivariés en termes de performance prédictive à des horizons de prévision de court terme.

Cependant, à des horizons de prévision plus étendus, les modèles multivariés semblent plus précis.

3.2 Le modèle VAR et cointégration

VAR standard :

Un modèle vectoriel autorégressif (VAR) est un ensemble d'équations linéaires dynamiques impliquant un ensemble de variables où chaque variable est utilisée pour expliquer toutes les autres variables dans le modèle.

Les modèles VAR sont de plus en plus utilisés dans la recherche macroéconomique au cours de la dernière décennie, en particulier aux États-Unis. Dans une large mesure, l'intérêt pour ces modèles s'est accru en raison des doutes sur l'utilité des modèles macroéconomiques "structurels" pour la prévision et l'évaluation des politiques. Les VARs sont non structurels et athéoriques.

Étant donné que de nombreuses variables influent sur l'inflation et sont à leur tour influencées par l'inflation, il est possible d'identifier une sélection de variables économiques dont l'évolution semble avoir été fortement corrélée à l'inflation dans la passée et qui, en tant que tels, peuvent être utiles pour prévoir l'inflation future.

L'approche VAR constitue un moyen pratique d'y parvenir, car elle s'appuie sur la relation de causalité et de rétroaction entre les variables.

Selon Lütkepohl (2005), un modèle VAR(p) est défini comme suit :

⁵La fonction **autocorrélation** (ACF) et l'**autocorrélation partielle** (PACF) sont des mesures de la corrélation entre les valeurs actuelles de séries (Y_t) et ses valeurs décalées (Y_{t-i}); elles indiquent les valeurs passées les plus utiles pour les prévisions futures.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

$$Y_t = C + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + U_t \quad \text{avec } t = 0, 1, 2 \dots \text{ et } E(U_t U_t') = \Omega$$

Où Y_t constitue un vecteur de n variables endogènes au moment t . Le vecteur peut, par exemple, inclure le taux d'inflation, le taux d'intérêt nominal, la masse monétaire ou d'autres variables :

$$Y_t = \begin{pmatrix} \text{Taux d'inflation} \\ \text{Taux d'intérêt nominal} \\ \text{Masse monétaire} \\ \vdots \end{pmatrix}$$

Les matrices A_i , pour $i = 1, \dots, p$, contiennent les coefficients du modèle. L'ordre p du modèle VAR indique le nombre de vecteurs retardés Y_{t-i} qui figurent dans le modèle.

Le vecteur U_t correspond à l'erreur et représente les influences non systématiques (dénommées également impulsions ou innovations). La matrice de variance-covariance Ω indique la structure de corrélation des erreurs et elle est supposée être non singulière.

L'estimation des paramètres équation par équation est basée sur les moindres carrés ordinaires (MCO).

La spécification d'un modèle VAR est basée sur quatre éléments :

- (i) La sélection des variables du modèle,
- (ii) La détermination de l'ordre du modèle,
- (iii) Le choix de composantes déterministes éventuelles et
- (iv) Le traitement des caractéristiques tendanciennes des variables (degré d'intégration et propriétés de cointégration).

Les prévisions sont générées à partir d'un modèle VAR de manière récursive. Ainsi, le VAR génère des prévisions pour chaque variable incluse dans le système. Pour illustrer le processus, les prévisions pour $T+h$ pour un modèle $VAR(p)$ sont alors générées par :

$$E_t[y_{t+h}] = C + A_1 E_t[y_{t+h-1}] + \dots + A_p E_t[y_{t+h-p}]$$

Avec $E_t[y_{t+i}] = y_{t+i}$, $\forall i \leq 0$

VAR avec cointégration :

Dans la pratique, la plupart des séries économiques ne sont pas stationnaires et, par conséquent, l'estimation des MCO conduira à des résultats erronés. On parle donc de régression fallacieuse. Engle et Granger (1987), ont montré que l'estimation par MCO peut encore être valide si une relation linéaire entre deux séries (même non stationnaires) est utilisée.

Si les variables sont non stationnaires et non cointégrées, alors elles doivent être transformées en variables stationnaires par différenciation, avant que le VAR puisse être estimé.

Ainsi ils affirment que, si des relations de cointégration existent entre des variables qui sont intégrées d'ordre 1, un modèle peut être spécifié comme un VECM (vector error correction model) plutôt qu'un VAR.

Par conséquent, si les variables sont intégrées d'ordre 1 tout étant cointégrées, c'est-à-dire qu'il peut y avoir une relation d'équilibre à long terme entre elles.

À l'aide de ce VECM, le test de cointégration de Johansen est utilisé pour déterminer si les variables sont cointégrées. Les tests de trace et de valeur propre maximale sont utilisés pour déterminer le rang de cointégration.

Selon les tests d'hypothèses, s'il existe des preuves de cointégration, cela signifie que l'information à long terme doit être incluse dans le modèle.

La VECM fournit une fonction de correction des erreurs (à long terme) pour capturer les relations dynamiques entre les variables à court terme ainsi qu'un cadre pour l'estimation d'un modèle cointégré dans le but d'améliorer les prévisions à long terme.

La formulation économétrique du VECM est générée par ;

$$\Delta Y_t = \delta + \Pi Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i} + \varepsilon_t$$

Où, Γ_i , $i = 1, \dots, p - 1$, (qui sont des fonctions de A_i) reflètent la relation dynamique à court terme, Y_t sont des variables indépendantes $I(1)$, $\Delta = (1 - L)$ tel que L est l'opérateur de retard, δ est l'intercept, Π est la matrice contenant l'information à long terme et ε_t est le résidu.

Pour la mise en place du modèle de prévision à l'aide de VECM on doit passer par les étapes fondamentales. A savoir :

- **Test de stationnarité :** L'hypothèse qui doit être satisfaite dans l'analyse VECM est que toutes les variables indépendantes doivent être stationnaires. Elle est caractérisée par le fait que tous les restes sont des bruits blancs à moyenne nulle, une variance constante et une absence de corrélation entre les variables dépendantes. Il existe plusieurs façons de mesurer la stationnarité des données, comme le test de Dickey-Fuller augmenté (ADF).

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- **Test de cointégration** : La cointégration est une relation à long terme entre les variables, qui bien qu'individuellement ne sont pas stationnaires, mais la combinaison linéaire de ces variables peut être stationnaire. La cointégration est un moyen d'éviter le problème de la régression fallacieuse. Une façon de tester la cointégration est d'utiliser le test de Johansen.
- **Test de l'hypothèse résiduelle** : Le test de l'hypothèse résiduelle sur le modèle VECM doit satisfaire les critères résiduels. A savoir une distribution normale des résidus (test de l'hypothèse de normalité), l'absence de corrélation sérielle entre les résidus (test de l'hypothèse d'autocorrélation), et l'homoscédasticité des résidus (test de l'hypothèse d'hétéroscédasticité).
- **Test du retard optimal** : Le test du décalage optimal consiste à déterminer la longueur du décalage à utiliser dans l'estimation du modèle VECM. Une détermination optimale du décalage est importante dans l'analyse utilisant la méthode VECM. En effet, si l'ensemble de retards est trop long ou trop court, la spécification du modèle sera erronée.
Les critères peuvent être utilisés pour déterminer le lag optimal entre l'erreur de prédiction finale (FPE), le critère d'information d'Akaike (AIC), Critère d'information de Schwarz (SIC) et Critère d'information de Hannan-Quinn (HQ), qui a une valeur minimale parmi les différents lags soumis. Mathématiquement, les valeurs de l'AIC, SIC et HQ peuvent être trouvées en utilisant la formule suivante.
- **Test de causalité de Granger** : Le test de causalité de Granger peut indiquer si une variable a une relation à double sens ou à sens unique.
Ce test est réalisé pour déterminer l'influence d'une variable sur une autre variable.
Il convient de rappeler que dans ce test de causalité de Granger, ce que l'on observe est l'effet du passé sur la condition actuelle, de sorte que les données utilisées sont des données de séries chronologiques.
- **Prédiction**

Section 3 : La politique monétaire et le contrôle de l'inflation

Dans cette section du premier chapitre, il nous paraît judicieux d'aborder le rôle de la politique monétaire étant le garant de la stabilité de prix et les mesures prises pour le contrôle de l'inflation.

Les décideurs de la politique monétaire font appel à trois types d'analyse pour la mise en œuvre de la stratégie de la politique monétaire. Ces analyses sont primordiales pour la prévision de l'inflation. A savoir :

- **L'analyse économique** a pour but d'identifier les risques à court et à moyen termes pesant sur la stabilité des prix (l'objectif ultime de la BCT). Elle est fondée sur l'étude d'une large gamme de variables macro-économiques : Le PIB, IPC, Indice de la production industrielle, etc.
- **L'analyse monétaire** apporte un élément de recoupement, dans une perspective de moyen et de long terme, des indications à court terme ressortant de l'analyse économique. Elle prend en compte des indicateurs tels que les agrégats monétaires et ses composantes - des plus liquides aux moins liquides.
- **L'analyse des canaux de transmission** : Les canaux de transmission désignent l'ensemble des mécanismes qui se déclenchent suite à l'actionnement des instruments de la politique monétaire contrôlés par la Banque Centrale en vue d'agir sur la stabilité des prix.

1. Définition et objectifs de la politique monétaire

1.1 Définition générale

La politique monétaire est, comme l'affirme Mishkin (1995), de plus en plus au centre de l'élaboration de la politique macroéconomique.

Le rôle principal de la politique monétaire en Tunisie est de veiller à la stabilité des prix mesuré par le taux de l'inflation.

Ce qui consiste à fournir les liquidités nécessaires à la croissance de l'économie tout en garantissant la stabilité de la monnaie. De ce fait, l'augmentation de la quantité de monnaie disponible dans l'économie ne doit être ni trop faible (le risque est de limiter l'activité économique, si les moyens de paiement en circulation sont insuffisants), ni trop rapide par rapport à la croissance de la production (le risque est de provoquer une hausse des prix, inflation, si le pouvoir d'achat à la disposition des agents est supérieur à l'offre de biens et services disponibles).

1.2 Les objectifs de la politique monétaire

Les objectifs de la politique monétaire des banques centrales sont généralement fixés par leurs statuts. Ce statut diffère d'un pays à l'autre, et fixe des objectifs ainsi que leurs niveaux. Ces objectifs peuvent inclure, en plus de la stabilité des prix, d'autres objectifs, comme une croissance élevée et un taux d'emploi maximum.

La Banque centrale européenne a ainsi pour « objectif principal de maintenir la stabilité des prix ». Tandis que la Réserve fédérale américaine a trois objectifs. Ainsi elle doit prioritairement, chercher à influencer le taux de chômage tout en maintenant la stabilité des prix, tandis que la BCE a pour objectif fondamental la seule stabilité des prix.

En Tunisie, selon la «loi n°2016-35 du 25 avril 2016 portant fixation du statut de la BCT», l'objectif principal de la BCT est d'assurer la stabilité des prix, autrement dit, la maîtrise du niveau de l'inflation mesurée par l'IPC, de contribuer à la stabilité financière de manière à soutenir la politique économique du gouvernement en termes de croissance et d'emploi. En fait, pour atteindre les objectifs finaux, la BCT doit passer par des objectifs intermédiaires :

Les objectifs finaux :

Comme toute politique économique, la politique monétaire vise à atteindre ses objectifs finaux comme la stabilité des prix, la croissance économique, le plein emploi et l'équilibre extérieur selon le « carré magique » de Kaldor.

De nos jours, la plupart des autorités monétaires dans le monde, sont conscientes du poids des coûts économiques et sociaux de l'inflation et accordent de plus en plus d'importance à la stabilité des prix.

Cet objectif est considéré comme l'objectif premier, dont les banques centrales cherchent à atteindre tout en travaillant sur d'autres objectifs

Toutefois, la politique monétaire ne peut pas viser directement ces objectifs car elle n'a qu'un contrôle indirect des grandeurs économiques et leurs mécanismes de décalages. C'est pour cette raison que la banque centrale fait appel aux objectifs intermédiaires.

Les objectifs intermédiaires :

Les autorités monétaires font appel à des objectifs intermédiaires pour atteindre leur but ultime vu qu'ils sont rapidement observables et mieux contrôlables. Ils constituent ainsi le levier d'action de la politique monétaire.

Parmi ces objectifs on distingue : les agrégats monétaires, le taux d'intérêt à court ou à long terme, le taux de marché monétaire, le taux de change, etc.

2. Les instruments de la politique monétaire face à l'inflation

Les banques centrales peuvent atteindre leur objectif premier de stabilité des prix au moyen de plusieurs instruments.

Ces instruments représentent le cadre opérationnel de la politique monétaire et permettent de contrôler la masse monétaire en circulation dans l'économie ainsi que coût des crédits accordés aux particuliers et entreprises.

2.1 La politique de pilotage de taux d'intérêt

Pour atteindre son objectif premier, la stabilité des prix, la BCT utilise le taux d'intérêt en tant qu'instrument principal de conduite de la politique monétaire. Ainsi, en fonction de ses anticipations sur l'inflation future et la croissance économique, la BCT ajuste le niveau de son taux d'intérêt directeur qui influence directement le taux interbancaire au jour le jour (TM), considéré comme cible opérationnelle de la politique monétaire.

Celui-ci influence, à son tour, le taux moyen mensuel du marché monétaire (TMM) d'où le contrôle de la liquidité bancaire ce qui permet in fine d'agir sur les conditions de financement de l'ensemble des acteurs économiques.

Les opérations à l'initiative de la BCT (à caractère discrétionnaire) :

Les opérations à l'initiative de la BCT ont trois objectifs : Le pilotage du taux d'intérêt interbancaire au jour le jour, l'ajustement de la liquidité bancaire et d'indication de l'orientation de la politique monétaire (une diffusion d'information indirecte aux établissements de crédit).

Ces opérations se divisent en quatre catégories définies comme suit

- **Opérations principales de refinancement** : Sous forme d'appel d'offre hebdomadaire : C'est l'outil principal d'apport de liquidité par la BCT. Elles jouent un rôle déterminant dans le pilotage des taux d'intérêt et signalent l'orientation de la politique monétaire de façon cohérente avec l'objectif final de stabilité des prix.
- **Opérations de refinancement à plus long terme** : Ces opérations ont pour objet de fournir des liquidités additionnelles pour des échéances plus longues que celles des opérations principales de refinancement. Elles sont réalisées au moyen d'opérations de cession temporaire sous forme de prêts garantis ou de prises en pension.
- **Opérations de réglage fin** : Ce sont opérations ponctuelles effectuées pour corriger l'effet des fluctuations imprévues de la liquidité bancaire sur les taux d'intérêt. Leur durée est inférieure à celle des opérations principales de refinancement. Parmi ces

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

opérations on distingue : L'open market (achat/vente de BTA), les swaps de change à des fins de politique monétaire.

- **Opérations structurelles** : L'utilité de cette opération est la gestion d'une situation de déficit ou d'excédent de liquidité durable.

Les appels d'offre (à caractère non discrétionnaire) :

Les banques peuvent recourir à leur propre initiative aux facilités permanentes de BCT destinées à fournir et retirer des liquidités au jour le jour. Le corridor formé par les taux des facilités de prêt et de dépôt définit la fourchette théorique de fluctuation du taux Over-night sur le marché interbancaire. Le conseil d'administration de la BCT décide régulièrement des taux d'intérêt applicables aux facilités permanentes (facilité de prêt marginal et facilité de dépôt) et de la date de leur entrée en vigueur.

2.2 Le contrôle de concours à l'économie :

La façon la plus directe de contrôler la création monétaire est de contrôler l'action de crédit qui en est l'origine. Cela se fait à travers : l'encadrement, la sélectivité et l'administration directe de crédits.

L'encadrement de crédit a une finalité quantitative et consiste à imposer aux banques des normes maximales obligatoires de progression des crédits. Toutefois, ce dispositif a été abandonnée en 1987 par la "circulaire 87-47 relative aux modalités d'octroi, de contrôle et de refinancement des crédits."

La sélectivité a une finalité qualitative et elle est destinée principalement à orienter la distribution du crédit dans la direction souhaitée par la stratégie de l'autorité monétaire ou la stratégie économique du gouvernement (vers des secteurs privilégiés).

Ce système se traduit par l'attribution des conditions privilégiés de crédits comme des bonifications des taux d'intérêts, des facilités de financement et des avantages fiscaux. L'administration directe de la distribution du crédit à travers le plafonnement des concours apportés par la BCT aux banques à travers le refinancement

2.3 Les réserves obligatoires :

Parallèlement à l'instrument de taux d'intérêt directeur adopté par la politique monétaire, les réserves obligatoires (non rémunérées) des banques sur leurs comptes courants à la BCT (sous forme de dépôts), est un instrument privilégié du fait de son impact immédiat sur la liquidité et la création monétaire des banques via le canal du crédit.

La BCT étant le régulateur de la liquidité, vise par l'administration des réserves obligatoires à lisser les fluctuations des taux d'intérêt au jour le jour (TM) et à contrôler la liquidité sur le marché monétaire.

3. Les canaux de transmission de la politique monétaire

La banque centrale affecte les variables réelles de l'économie à travers les instruments mises en œuvre par la politique monétaire en vue d'atteindre l'objectif de stabilité des prix (Ozdogan, 2009). Une telle stratégie nécessite une évaluation continue du le rythme et l'incidence de l'actionnement de ces instruments sur l'économie réelle, à travers une compréhension et une analyse des mécanismes de transmission par lesquels la politique monétaire affecte l'économie.

La connaissance des mécanismes de transmission est une donnée indispensable pour la conduite de la politique monétaire. Et ils sont déterminants pour comprendre la dynamique de l'inflation.

La théorie traditionnelle identifie trois canaux, à savoir : le taux d'intérêt, le taux de change et le canal des actifs.

Cependant, des travaux récents ont ajouté trois autres canaux, le canal du crédit, le canal des bilans bancaires et le canal des anticipations (Mishkin., 1996 ; 14).

3.1 Le canal du taux d'intérêt

Selon la théorie keynésienne, le canal du taux d'intérêt est le principal mécanisme de transmission de la politique monétaire et désigne l'ensemble des moyens par lesquels un changement du taux d'intérêt directeur de la banque centrale susceptible d'influer la sphère réelle de l'économie par le biais des décisions d'investissement et de consommation des ménages et des entreprises.

Ainsi, dans une politique monétaire expansionniste, une baisse du taux directeur et donc des taux d'intérêt réelle aboutit à la réduction du cout de capital ce qui mène à une augmentation des dépenses d'investissement et un accroissement de la demande globale et la production.

En outre, une hausse de taux d'intérêt par la banque centrale ralentit la demande, l'activité et l'inflation.

La spécificité du canal de taux d'intérêt est le fait qu'il met l'accent sur le taux d'intérêt réel plutôt que nominal comme étant un indicateur capital qui affecte les décisions des agents économiques. De ce fait, il est potentiellement renforcé par trois effets significatifs sur les comportements de dépenses des acteurs économiques, à savoir : un effet de revenu, un effet de substitution et un effet de richesse, qui conduisent les ménages à arbitrer entre la consommation présente et l'épargne future ou vice-versa.

3.2 Le canal du crédit

Le mécanisme du canal du crédit bancaire décrit la théorie selon laquelle la politique monétaire affecte l'économie réelle non seulement en modifiant les taux d'intérêt à court terme, mais aussi en modifiant la disponibilité et les conditions (ajustement de la quantité) des crédits accordés par les banques aux entreprises et ménages.

Cette approche se distingue par rapport au mécanisme du taux d'intérêt du fait qu'elle met l'accent sur ce qui se passe à l'actif des bilans des institutions financières (volume et conditions des prêts bancaires) et non par la modification des conditions de financement direct par le recours au marché.

De ce fait une politique monétaire expansionniste qui contribue à l'accroissement des réserves et des dépôts ainsi bancaires, augmente le volume des prêts dans les bilans des banques et un resserrement de la politique monétaire qui se traduit par une réduction des dépôts, doit s'accompagner d'une contraction l'autre côté des bilans des institutions bancaires.

3.3 Le canal du taux de change

Le canal du taux de change (également appelé « *passthrough* » du taux de change) joue un rôle non négligeable dans le cadre de l'internationalisation évolutive des économies. Dans une économie à régime de change flexible, les changements du taux directeur peuvent induire des fluctuations des taux de change.

Par la suite le taux de change influence la sphère réelle de l'économie en agissant sur les prix et la compétitivité des entreprises ce qui affecte les équilibres macroéconomiques.

Toute chose étant égale par ailleurs, une baisse des taux d'intérêt entraîne une dépréciation du cours de la monnaie, ce qui stimule les exportations nettes et la production nationale.

De plus, cet indicateur joue un rôle important dans la détermination de la dynamique de l'inflation, surtout, dans les petites économies largement ouvertes.

La littérature existante stipule que le taux de change nominal est pris en compte dans la conduite d'une politique monétaire optimale lorsque ses fluctuations influencent les écarts d'inflation ou de production.

Un large courant de la littérature souligne qu'il est important de procéder à une évaluation degré de pass-through car cet élément entre en ligne dans la mise en œuvre de la conduite de la politique monétaire (Mishkin, 2008 ; Edwards, 2006).

En effet, un degré faible de pass-through signifierait que les variations du taux de change ont moins d'effets sur les prix à la consommation et, par conséquent, sur le taux d'inflation à court

terme. Cela pourrait influencer les prévisions des banques centrales sur le comportement futur de l'inflation.

3.4 Le canal des actifs financiers

L'actionnement de la politique monétaire affecte les prix des actifs tels que les actions, les obligations et l'immobilier, modifiant les valeurs boursières des entreprises ainsi que la richesse des ménages, qui affectent à leur tour la demande globale.

Le canal de transmission de la politique monétaire par les prix des actifs est supposé fonctionner à travers deux mécanismes, à savoir : la valeur de Tobin (théorie des choix d'investissement, 1969) et la valeur de l'actif (la théorie de la consommation du cycle de vie d'Ando-Modigliani (1963)).

Le Q de Tobin mesure le rapport entre la capitalisation boursière d'une entreprise et le coût de renouvellement de capital de celle-ci.

Ainsi, selon Keynes une politique monétaire expansionniste augmente la demande d'actions, ce qui fait augmenter le prix des actions et donc la valeur boursière des entreprises par rapport au coût de renouvellement du capital ce qui mène à une augmentation de l'investissement et donc de la production. En outre, l'augmentation du prix des actions engendre un accroissement de la valeur nette des entreprises et les ménages améliorent donc leur solvabilité et leur accès aux fonds dont les effets reflètent en partie le canal du bilan de la politique monétaire (Afandi, 2005). Dans le modèle de consommation Ando-Modigliani, les actions de politique monétaire affectent la richesse à long terme des acteurs économiques et modifient donc leurs habitudes de consommation.

Le principe de base de cette théorie est que les ménages lissent leur consommation dans le temps et que cette consommation dépend des ressources de sur une longue période et pas seulement de la consommation courante (Mishkin, 1996).

De ce fait, la baisse des taux d'intérêt (une politique monétaire expansionniste) modifie la composition du portefeuille des ménages en fonction du risque de chaque classe d'actifs.

Cette baisse incite les agents économiques à réduire leur détention des dépôts et des obligations productifs d'intérêts en les remplaçant par des actions, ce qui fait augmenter le prix des actions.

3.5 Le canal des bilans bancaire

Le canal large du crédit ou canal des bilans bancaires repose sur l'idée que les mécanismes de transmission de la politique monétaire à l'économie réelle dépendent aussi de la qualité de la structure du bilan des agents économiques (particuliers et ménages).

Dès lors, une hausse des taux d'intérêt aura des effets dépressifs et plus importants si les agents privés sont auparavant déjà surendettés et peu solvables. Ainsi, un durcissement monétaire aura un impact négatif sur la capacité de remboursement des entreprises (canal du taux d'intérêt) et sur le coût de leur capital (Q de Tobin). Cet impact sera renforcé par un redressement de "la prime de risque" pesées sur les nouveaux emprunteurs par les banques.

3.6 Le canal des anticipations

Dans la macroéconomie moderne, il est admis que les anticipations influencent le comportement des agents économiques.

Selon Keynes (1936), dans sa Théorie générale : "...le comportement de chaque entreprise individuelle, lorsqu'elle décide de sa production quotidienne, sera déterminé par ses attentes à court terme à travers les anticipations quant au coût de la production à différentes échelles possibles et anticipations quant au produit de la vente de cette production."

Les économistes s'accordent généralement sur l'idée que les attentes des agents économiques impactent l'activité économique, mais ils diffèrent sur le mécanisme sous-jacent générateur de ces attentes.

Friedman et d'autres monétaristes postulent la théorie des attentes adaptatives (les individus ont dû s'adapter aux événements passés) tandis que la nouvelle école keynésienne plaide pour des attentes rationnelles (les individus basent leurs décisions sur les informations qu'ils ont à un instant T).

Les agents économiques étant rationnels et tournés vers le futur le canal des anticipations est en fait fondamental pour un fonctionnement optimal de tous les canaux de transmission de la politique monétaire qui converge avec son objectif final.

Empiriquement, ce canal est principalement opérationnel dans les économies développées et financiarisées (Davoodi et al., 2013).

Par exemple, si les ménages anticipent des changements futurs du taux directeur, cela peut immédiatement affecter les taux d'intérêt à moyen et long terme.

Ainsi, les modifications de l'orientation de la politique monétaire influencent le comportement en matière de fixation des prix et des salaires et ce par conséquent répercutent sur l'inflation réelle au cours des périodes suivantes.

De ce fait, un ancrage réussi des anticipations permet à la banque centrale de gagner en crédibilité et transparence.

Pour se faire, la banque centrale doit veiller à la mise en œuvre d'une stratégie de communication bien étudiée dans le cadre de "*forward guidance*". Cette stratégie est

considérée, tant dans la littérature universitaire que dans la pratique, comme un élément central de l'efficacité de la politique monétaire puisqu'elle rend les attentes du marché concernant les actions futures de politique monétaire plus stables.

4. Le *reporting* des prévisions sur l'inflation & la transition au régime de ciblage d'inflation

Dans une stratégie de ciblage de l'inflation, l'avantage de base que la politique monétaire est guidée par un critère simple et clair : l'écart entre l'inflation future ou prévue et l'inflation cible. Toutefois, cette simplicité peut être trompeuse.

Pour mettre en place ce dispositif de ciblage, la prévision d'inflation doit être de la meilleure qualité possible pour permettre les décideurs de la politique monétaire de prendre les décisions adéquates au bon moment.

En outre, la réponse de la politique à un écart donné entre le prévue et le cible n'est pas unique. Elle dépendra toujours de plusieurs autres considérations, notamment les préférences du décideur, l'impact de la politique monétaire sur la croissance de la production et le chômage, ainsi que les conditions actuelles ou prévues de la conjoncture économique.

En d'autres termes, le ciblage de l'inflation est un cadre sensible aux implications politiques imprécises, et pour être compris et généralement accepté, il doit être accompagné d'une communication claire, fiable et précise des prévisions sur l'inflation.

De ce fait, la transparence est essentielle car la politique monétaire dépend de manière cruciale des perceptions du marché.

C'est sans doute la raison pour laquelle toutes les banques centrales ayant pour cible l'inflation ont donné beaucoup d'importance aux prévisions de l'inflation et ont adopté un dispositif pour communiquer au public des rapports sur l'inflation.

De nombreuses banques centrales fournissent également une indication du degré de confiance dans la prévision d'inflation dans des rapports détaillés en rassurant le public sur le fait qu'elles s'appuient sur des techniques de pointe.

Cette communication sur les prévisions est nécessaire dans la mesure où elle permet d'expliquer au grand public l'importance de la stabilité des prix pour mieux orienter les anticipations des futures actions de politique monétaire.

L'efficacité de la politique monétaire est donc renforcée lorsque la banque centrale peut influencer les attentes du marché à long terme. Puisque qu'elle ne peut pas s'engager sur une ligne de conduite sur plusieurs années, le mieux qu'elle puisse faire est de s'assurer que les marchés perçoivent clairement sa logique et ses implications stratégiques

Ainsi, en étant transparentes les banques centrales peuvent orienter la pensée des agents économiques dans marché et affecter indirectement les taux d'intérêt à long terme, le taux de change et les prix des actifs.

La BCT a tracé une feuille de route pour la mise en œuvre d'une stratégie de ciblage de l'inflation, un dispositif robuste de prévision constitue alors un proxy pour le passage à cette stratégie.

End et Kolsi (2020) affirment que la BCT est en bonne position pour publier un rapport de politique monétaire. Le rapport "**Evolutions Economiques et Monétaires et Perspectives à Moyen Terme**" présente déjà de nombreuses caractéristiques d'un rapport de politique monétaire efficace.

Depuis octobre 2018, le rapport est publié régulièrement et inclut les projections d'inflation de la BCT.

Les « **périodiques de conjoncture** » également sont publiés chaque trimestre et comportent une analyse des faits saillants de la conjoncture internationale et nationale

Notamment dans le rapport annuel de 2019, la BCT inclut une nouvelle section qui porte sur la conjoncture internationale.

De plus, Le règlement de mise en œuvre de la politique monétaire, les modèles de prévision ainsi que les études récentes sont publiés sur son site internet.

Conclusion

L'objectif de ce premier chapitre est de mettre en exergue la place prééminente de l'inflation dans la conduite de la politique monétaire, la préservation de l'équilibre économique, et la stabilité des prix qui est l'objectif premier de la BCT.

Nous avons exposé une vue générale sur l'inflation, ses mesures, sa dynamique, ses déterminants, le rôle de la politique monétaire dans le contrôle de l'inflation, les différentes mesures mises en place pour faire face à ce phénomène ainsi que l'importance du dispositif de prévision de l'inflation pour la transition au régime de ciblage de l'inflation.

Ainsi, la Tunisie s'oriente progressivement vers une flexibilité totale de son taux de change et vers un cadre de ciblage de l'inflation.

Une transition réussie vers le régime de ciblage de l'inflation dépend non seulement des conditions préalables à l'adoption de cette stratégie, mais aussi de la capacité à prévoir l'inflation qui va devenir une tâche essentielle pour la BCT.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

En raison des délais entre la politique monétaire et ses effets sur l'économie, en particulier sur l'inflation, la BCT devra fonder ses décisions de politique monétaire non pas sur les résultats passés de l'inflation, mais sur les prévisions d'inflation.

La précision avec laquelle l'inflation peut être prévue est un élément essentiel du cadre de ciblage de l'inflation.

La BCT utilise un large ensemble d'informations provenant des jugements d'experts, et d'une variété de modèles allant de simples modèles traditionnels de séries chronologiques à des modèles théoriquement bien conçus.

Dans le deuxième chapitre dont nous avons exposé en premier lieu l'état de l'art des modèles économétriques de prévision de l'inflation et en second lieu nous nous intéressons aux revues de littérature sur les techniques de Machine Learning et leur apport dans la prévision de l'inflation en particulier. Enfin, nous présentons une application empirique sur des données tunisiennes.

CHAPITRE 2 : LES TECHNIQUES DE MACHINE LEARNING : PRINCIPE & APPLICATION EMPIRIQUE SUR DES DONNEES TUNISIENNES

Introduction

Les méthodes de prévision macroéconomique se sont considérablement améliorées au cours des cinquante dernières au point qu'elles sont capables de générer des prévisions relativement précises des indicateurs macroéconomiques. Cependant ces approches présentent diverses propriétés indésirables, allant d'une grande sensibilité des résultats à la spécification économique du modèle jusqu'à des exigences élevées en matière de données qu'elles soient objectives ou relatives à des appréciations des divers agents économiques. De plus, les relations entre les séries financières et économiques sont souvent non linéaires par nature, ce qui remet en question l'utilisation commune de modèles linéaires pour leur prévision.

Ainsi, suite à la disponibilité de grands ensembles de données, les progrès des algorithmes numériques et les améliorations méthodologiques dans l'analyse des données (data science), il existe une marge de manœuvre considérable pour faire progresser les prévisions macroéconomiques et spécifiquement la prévision de l'inflation en tirant parti des progrès récents de l'apprentissage automatique ou Machine Learning.

Cette technique s'est imposée comme un nouveau paradigme scientifique dans de nombreuses sciences et son utilisation dans l'économie suscite l'intérêt des décideurs de la politique économique.

Depuis la crise financière mondiale de 2008/09, de nombreuses banques centrales et régulateurs ont eu de nouvelles responsabilités en termes de surveillance et de contrôle des marchés.

Ces responsabilités se sont accompagnées de la collecte d'une multitude de nouvelles sources de données et de l'accès à celles-ci, ce qui fait entrer les banques centrales dans le domaine du Machine Learning et Big Data.

Selon un rapport publié par Irving Fisher Committee, la majorité de banques centrales utilise les techniques de ML appliquées des données structurés et non structurés pour soutenir leurs analyses économiques, leurs décisions politiques et leurs prévisions, notamment dans les domaines de la recherche économique, de la stabilité financière et de la politique monétaire.

Cependant, même avec un nombre limité de données, les techniques de ML s'avèrent être utiles comme un outil d'aide à la décision.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Citons par exemple la banque d'Angleterre et la réserve fédérale (FED) qui font appel à plusieurs algorithmes de ML pour la prévision de l'IPC en se basant sur des prédicteurs clés.

Pour la Banque du Canada le ML est utilisé pour effectuer une analyse des sentiments sur les enquêtes et les rapports de politique monétaire pour améliorer les prévisions et détecter les anomalies.

De son côté, la BCE collecte quotidiennement des données auprès de MTS Markets (une plateforme de négociation numérique pour les gouvernements) afin de produire des courbes de rendement quotidiennes pour la zone euro et utilise les données de Google à des fins de prévision immédiate à des fins de prévision immédiate.

La Banque de Grèce utilise des algorithmes d'exploration de données sur des données collectées à partir des prêts aux entreprises et aux PME du système bancaire grec afin de réduire la dimensionnalité et d'augmenter la précision dans la prédiction du comportement futur des entreprises (Petropoulos et al., 2018).

L'objectif de ce chapitre est de présenter une vue d'ensemble sur l'apprentissage automatique avec une application empirique centrée autour de la prévision de l'inflation en Tunisie.

Et pour des raisons de clarté, on commence par des généralités associées au terme "Intelligence Artificielle" ainsi que l'application de cette discipline dans un contexte économique. Cela nous paraît nécessaire car l'apprentissage automatique et l'intelligence artificielle sont souvent utilisés de manière interchangeable.

Dans la deuxième section, nous présentons l'histoire du Machine Learning, ses principes, ses applications, les types d'apprentissages, les principaux algorithmes, ainsi que les étapes d'un projet de ML. De plus, nous exposons les algorithmes qui sont utiles pour les prévisions macroéconomiques ainsi que le langage de programmation choisi et son importance dans l'implémentation de ces algorithmes. Dans la troisième section, nous aborderons les principales différences et les similitudes entre la discipline de ML et celle de l'économétrie.

Ensuite, une application des techniques de ML sur des données tunisiennes est présentée avec une comparaison avec un benchmark économétrique.

Nous terminons par les enjeux et les limites de cette discipline pour les décideurs de la politique économique.

Section 1 : Contextualisation et généralités sur l'intelligence artificielle

Historiquement, l'intelligence artificielle en tant que domaine scientifique, trouve ses origines dans les années 1950 quand le mathématicien britannique Alan Mathison Turing (auteur de travaux qui fondent la science informatique) se demande si une machine peut « penser ».

Dans son article « Computing Machinery and Intelligence » (Mind, octobre 1950), il propose une expérience (dite test de Turing) visant à trouver à partir de quand une machine deviendrait « consciente ».

Dans son expérience, un examinateur est confronté à deux interlocuteurs, l'un étant un ordinateur, l'autre humain. À l'aide d'échanges textuels, il doit alors identifier lequel des deux est une machine. S'il échoue, l'ordinateur a alors passé le test avec succès. Dans ce contexte, les premiers programmes « intelligents » voient le jour.

Créé par son principal pionnier John McCarthy, le terme « intelligence artificielle » désigne un ensemble de logiciels, de logiques, de calculs et de disciplines philosophiques qui ont pour objectif d'amener les ordinateurs à exécuter des fonctions jusqu'alors perçues comme étant propres à l'être humain puisqu'elles exigent un apprentissage, une organisation de la mémoire, une perception et un raisonnement spécifique.

Le volet « artificiel » est associé à l'usage des machines et le côté « intelligence » représente l'ensemble des processus retrouvés dans des systèmes, plus ou moins complexes, vivants ou non, qui permettent la capacité d'apprendre, d'assimiler, et de traiter l'information pour atteindre des objectifs.

En 1956, Marvin Lee Minsky, scientifique américain et l'un des créateurs de l'IA, la définit comme étant « *la construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisante par des êtres humains, car elles demandent des processus mentaux de haut niveau tels que : l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique.* »

Notamment, l'intelligence artificielle est un domaine vaste qui touche autant à l'informatique qu'aux mathématiques, mais également à la neuroscience et même à la philosophie.

Avec l'émergence de Big Data & de Cloud Computing avec une puissance de calcul peu coûteuse, l'IA a beaucoup évolué. Ainsi, les machines ne sont plus programmées ; elles apprennent.

En 1997, une machine dotée d'IA développée par IBM⁶ fait ses preuves et réussit à battre le champion mondial d'échecs, Garry Kasparov. Depuis, les machines intégrant dans leurs programmes l'intelligence artificielle n'ont cessé de surpasser les hommes. En 2015, L'une des dernières défaites du cerveau humain face à l'IA étant celle du champion de Go face à l'intelligence artificielle développée par Google : AlphaGO⁷.

De nos jours, les domaines d'application et usages potentiels d'une Intelligence Artificielle sont de plus en plus divers : reconnaissance visuelle, robotique, compréhension du langage naturel (NLP) système autonome et Machine Learning. Dans la prochaine section, nous nous intéressons à définir le Machine Learning, un champ d'application de l'IA ainsi que sa contribution aux prévisions macroéconomiques dans les banques centrales.

Section 2 : Exploration des techniques de Machine Learning

Au cours des deux dernières décennies et suite à l'émergence de Big Data, l'apprentissage automatique est devenu l'un des piliers des sciences des données et des technologies de l'information et constitue ainsi un ingrédient nécessaire au progrès technologique.

1. Définition de Machine Learning :

L'apprentissage automatique ("Machine Learning" *en anglais*), apprentissage statistique ou apprentissage artificiel est un champ d'application de l'intelligence artificielle qui se fonde sur des techniques mathématiques et statistiques pour donner aux systèmes informatiques la capacité d'« apprendre » à partir de données (améliorer leurs performances à résoudre des tâches spécifiques avec l'expérience) sans être explicitement programmés (Tom M. Mitchell, 1997, p. Xv).

Autrement dit, et pour une définition moins vague, la ML est considérée comme la combinaison d'algorithmes informatiques automatisés avec de puissantes méthodes statistiques ayant pour but apprendre (découvrir) des modèles cachés dans les données.

Ce domaine résulte de l'intersection de plusieurs disciplines. A savoir ; l'informatique, les statistiques et les mathématiques, ainsi que les idées provenant des neurosciences et d'autres sciences également.

Les méthodes de ML peuvent être divisées en trois groupes principaux : apprentissage supervisé, apprentissage non-supervisé et apprentissage par renforcement.

⁶ International Business Machines Corporation, connue sous le sigle IBM, est une multinationale américaine qui opère dans les domaines du logiciel et des services informatiques.

⁷ Le premier programme informatique à vaincre un joueur de Go humain professionnel.

Notons que dans les prévisions macroéconomiques, le type adopté est l'apprentissage supervisé.

2. Les types d'apprentissage :

Il existe tout un univers de techniques différentes d'apprentissage statistique et pas un seul type d'algorithme. Ces techniques sont classées essentiellement en trois grandes catégories : (1) les apprenants supervisés, (2) les apprenants non supervisés et l'apprentissage par forçage.

2.1 L'apprentissage supervisé

L'apprentissage supervisé est une tâche de Machine Learning qui consiste, comme son nom l'indique à superviser l'apprentissage d'une machine en lui montrons des exemples annotés (données) de la tâche qu'elle doit réaliser.

Cette technique est appliquée dans : la régression (si la variable est quantitative), la classification (si la variable est qualitative), ainsi que la reconnaissance vocale.

Pour ce faire, trois éléments nécessaires pour l'implémentation de ce type d'apprentissage :

- Un ensemble de données à exploiter. Les données peuvent être fournies sous forme de tableau, mais doivent être étiquetées avec les catégories correctes.
- Un modèle qui détermine comment la machine aborde le problème de l'évaluation des données, avec des paramètres qui affinent le modèle pour rendre les prédictions aussi précises que possible. Il existe de nombreux modèles d'apprentissage automatique.
- La fonction objectif qui calcule l'erreur, ou la distance qui sépare l'algorithme d'une performance parfaite.

2.2 L'apprentissage non supervisé

A la différence de l'apprentissage automatique supervisé, le contexte non supervisé est celui où l'algorithme de ML doit opérer à partir des données non annotées. Le but alors est de découvrir les structures sous-jacentes de ces données.

Ainsi, dans ce type d'apprentissage, les réponses qu'on cherche ne sont pas présentes dans les données fournies. Le rôle de la machine est de créer elle-même les réponses suite aux différentes analyses et au classement des données

Les techniques d'apprentissage automatique non-supervisé peuvent être appliqué pour résoudre, entre autres, ces problèmes :

- le partitionnement de données (l'algorithme des k-moyennes et le regroupement hiérarchique),
- L'estimation de densité de distribution (distribution de mélange, estimation par noyau),

- La réduction de dimension (comme l'analyse en composantes principales).

L'apprentissage non supervisé peut également être utilisé en conjonction avec une inférence bayésienne pour produire des probabilités conditionnelles pour chaque variable aléatoire étant données les autres.

2.3 L'apprentissage par forçage

Plutôt que de simplement manipuler des données, les algorithmes d'apprentissage par renforcement fonctionnent en introduisant un logiciel, appelé agent d'apprentissage automatique, dans un environnement et en lui apprenant comment agir. Ainsi, l'agent apprend les actions à prendre, à partir d'expériences, de façon à optimiser une récompense quantitative au cours du temps.

L'apprentissage par renforcement est très important dans le domaine de la robotique, bien que ses plus grands succès publics aient été de battre des humains dans des jeux.

DeepMind, une société d'intelligence artificielle de premier plan qui a été rachetée par Google en 2014, a été un pionnier de l'apprentissage par renforcement.

3. Les algorithmes de Machine Learning

Dans cette partie, nous allons sélectionner deux types de modèles de ML utilisés dans la prévision macroéconomique.

3.1 K-Nearest Neighbors et les modèles basés sur les arbres décisionnelles

3.2.1 Le modèle K-Nearest Neighbors (k-NN)

Le modèle K-Nearest Neighbors (k-NN en abrégé) est un modèle d'apprentissage automatique non paramétrique popularisé par les travaux d'Altman (1992).

Essentiellement, il s'agit d'un modèle utilisé dans les problèmes de classification et de régression et formé à l'aide de l'apprentissage supervisé.

Cet algorithme simple a été utilisé efficacement dans divers domaines de recherche, tels que la modélisation financière (Zhang et al., 2017), l'interpolation d'images (Ni et Nguyen, 2009) et la reconnaissance visuelle (Liu, 2016). L'algorithme k-NN a été appliqué avec succès dans la prévision des séries temporelles, malgré sa simplicité.

Par exemple, Tang et al. (2018) proposent un modèle de régression k-NN intégré avec une analyse en composantes principales (ACP) pour la prévision des séries chronologiques financières.

Zhang, et al. (2017) utilisent un modèle k-NN multidimensionnel combiné à une décomposition en mode empirique d'ensemble pour prédire le prix des actions.

Suivant Song et al. (2017), la régression k-NN repose sur l'apprentissage par comparaison d'instances de test données avec l'ensemble d'apprentissage.

Pour une métrique de distance sélectionnée d , soit $T = (x_1, y_1), \dots, (x_n, y_n)$ l'ensemble d'apprentissage. De même, que $x_i = (x_{i1}, \dots, x_{im})$ soit la i ème instance, désignée par m attributs et associée à l'ensemble d'apprentissage.

Pour une instance de test x donnée, pour laquelle une prédiction \hat{y} est souhaitée, l'algorithme procède comme suit : Les points x_i sont classés en fonction de la distance d_i à x . En considérant les k points les plus proches de x , la prédiction \hat{y} est définie comme suit :

$$\hat{y} = \frac{1}{k} \sum_{i=1}^k y_i(x)$$

Où $y_i(x)$ dépend de x car les k points sélectionnés sont basés sur leur distance à x .

3.2.2 Les modèles de Forêts aléatoires

Les forêts aléatoires sont un modèle introduit et popularisé par Breiman (2001). Il implique la combinaison de prédicteurs d'arbres de telle sorte que chaque arbre dépende des valeurs d'un vecteur aléatoire échantillonné indépendamment et avec la même distribution pour tous les arbres de la forêt.

En ce sens, le modèle représente une modification substantielle du bagging, puisqu'il construit une large collection d'arbres dé-corrélés pour le calcul de la moyenne postérieure, comme le prétendent Hastie, Tibshirani et Friedman (2008).

Sur de nombreux problèmes, les performances des forêts aléatoires sont comparables à celles du boosting, mais elles sont plus simples à former et à régler.

En effet, de telles propriétés émergent du fait que les Forêts aléatoires parviennent à réduire la variance des arbres de régression traditionnels, comme le préconise Vasconcelos (2018).

Dans une vision plus large, les Forêts aléatoires appartiennent à la classe des estimateurs d'arbres de régression.

Cette méthode est définie comme une collection de modèles non paramétriques flexibles qui partitionnent récursivement l'ensemble des variables indépendantes en sous-ensembles, chacun étant modélisé à l'aide de méthodes de régression.

Grâce à la figure 3, on peut observer comment fonctionne un arbre de régression. Le panneau inférieur gauche dévoile que, dans cet exemple, les variables

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

X_1 et X_2 ont été divisées pour produire cinq régions, $R_j, j = 1, \dots, 5$, dans lesquelles la variable dépendante est prédite comme étant une constante C_j .

Chaque région est définie en fonction de la valeur assumée par X_1 et X_2 . Par exemple, la région R_1 est associée à $X_1 \leq t_1$ et $X_2 \leq t_2$, où $t_k, k = 1, 2, 3, 4$, sont des paramètres à estimer.

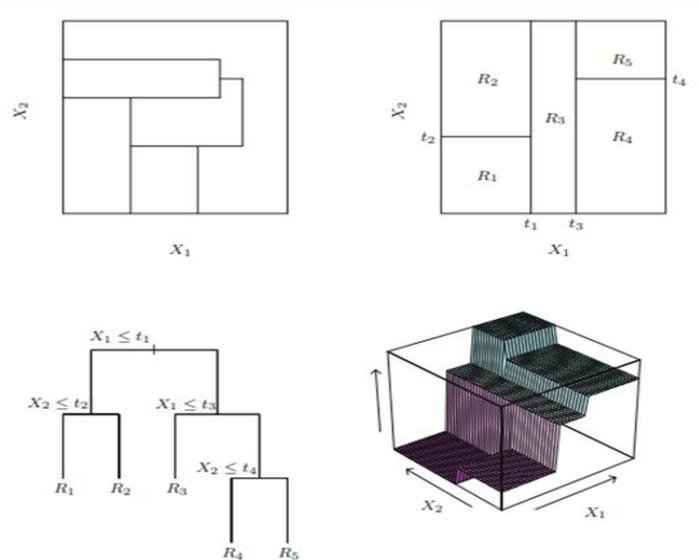


Figure 2. Architecture simplifiée des arbres de régression

Breiman (2001) souligne les caractéristiques souhaitables suivantes des forêts aléatoires, expliquant leur utilisation répandue dans de nombreuses applications pratiques :

1. Il y a une robustesse contre les valeurs aberrantes et le bruit ;
2. Il fournit des estimations internes utiles de l'erreur, de la force, de la corrélation et de l'importance des variables ;
3. Il est simple et facilement parallélisable⁸.

En raison de sa polyvalence et de sa puissance statistique, il existe plusieurs applications de forêts aléatoires dans la littérature.

Par exemple, Adekoya et Weyori (2019) développent un modèle de forêts aléatoires pour la prédiction des cours des actions en utilisant des variables macroéconomiques comme entrées, obtenant des erreurs absolues moyennes plus faibles par rapport à d'autres techniques de prévision de séries temporelles.

⁸ Le traitement parallèle signifie simplement que les algorithmes sont déployés sur plusieurs processeurs. En général, cela signifie un traitement distribué, un algorithme ML typique implique de faire beaucoup de calculs (travail/tâches) sur un grand nombre de données.

3.3 Les modèles d'apprentissage profond (*Deep Learning*)

L'apprentissage profond s'articule autour de l'hypothèse selon laquelle un modèle de ML profond, hautement hiérarchisé, peut être plus efficace pour représenter certaines fonctions qu'un modèle superficiel.

Par conséquent, l'apprentissage profond englobe plusieurs architectures de réseaux neuronaux formées de plusieurs couches cachées, par opposition aux réseaux peu profonds. Jusqu'en 2006, les préoccupations concernant les obstacles pour former les réseaux profonds expliquaient leur manque de popularité malgré leur potentiel.

En effet, Schmidhuber (2015) affirme que, dans les années 1990, les réseaux profonds de type *feedforward* ou récurrents étaient difficiles à former par rétropropagation, la raison principale étant la disparition ou l'explosion des gradients pendant l'optimisation.

Ce problème est connu sous le nom de "*problème fondamental de l'apprentissage profond*".

Au fil des années, d'autres solutions pour d'autres solutions pour surmonter le problème fondamental de l'apprentissage profond ont été introduites, comme les algorithmes d'optimisation « hessian free » et les ordinateurs basés sur les GPU, qui ont une puissance de calcul des CPU du début des années 1990.

De nos jours, ces avancées ont assuré la diffusion des modèles d'apprentissage profond dans de nombreux domaines de recherche et dans plusieurs applications pratiques.

Corroborant l'idée que l'apprentissage profond permet d'obtenir des modèles plus puissants en raison de l'existence de hiérarchies profondes, Eldan et Shamir (2016) démontrent mathématiquement que l'augmentation de la profondeur des réseaux neuronaux est généralement plus efficace que l'augmentation du nombre de neurones dans les réseaux existants.

À titre d'illustration, ils montrent que certaines classes de fonctions dans \mathbb{R}_d exprimables par un petit réseau neuronal à 3 couches, ne peuvent pas être approchées par un réseau à 2 couches avec plus d'une précision prédéfinie, sauf si le nombre de neurones par couche croît exponentiellement dans la dimension d . Le résultat est indépendant de la fonction d'activation. La supériorité du modèle d'apprentissage profond par rapport aux réseaux peu profonds est également soutenue par d'autres résultats théoriques.

Par exemple, Delalleau et Bengio (2011) présentent des familles de fonctions qui peuvent être représentées beaucoup plus efficacement (c'est-à-dire avec moins d'unités cachées) via des réseaux profonds plutôt que des réseaux superficiels.

De plus, ils démontrent que les réseaux génératifs profonds, mais étroits, ne nécessitent pas plus de paramètres que les réseaux peu profonds pour obtenir une approximation universelle.

3.3.1 Les réseaux de neurone artificiel de type feedforward

Développés par **Mc Culloch et Pitts (1943)**, les réseaux de neurones artificiels (ANN), ou simplement réseaux de neurones (NN), sont devenus un modèle d'apprentissage automatique très répandu.

Selon **Haykin (2004)**, les réseaux de neurones, appelés réseaux connexionnistes ou réseaux neuromimétiques, est l'association en un graphe plus ou moins complexe, d'objets élémentaires, les neurones formels.

Les principaux réseaux se distinguent par l'organisation du graphe ou leur architecture (en couches, complets) son niveau de complexité (le nombre de neurones, présence ou non de boucles de rétroaction dans le réseau), par le type des neurones (les fonctions d'activation) et enfin par l'objectif visé : apprentissage supervisé ou non, optimisation, systèmes dynamiques...

En ce sens, ils ressemblent au cerveau sous deux aspects :

1. Les connaissances sont obtenues par les réseaux à partir de leur environnement par un processus d'apprentissage et
2. Les forces de connexion entre les neurones, appelées poids synaptiques (ou simplement poids), sont utilisées pour stocker les connaissances acquises.

Avant de présenter les modèles avancés d'apprentissage profond, il est nécessaire de commencer par le réseau de neurone artificiel le plus simple, le *perceptron* considéré leur pierre angulaire.

Le perceptron a été inventé en 1957 par Frank Rosenblatt au Cornell Aeronautical Laboratory. Dans cette première version le perceptron était alors mono-couche et n'avait qu'une seule sortie à laquelle toutes les entrées étaient connectées. Le réseau *feed-forward*, avec la topologie d'un graphe acyclique dirigé, et le neurone construit comme un perceptron. Ce type de réseau est utilisé dans les problèmes de classification et de régression. Prenons par exemple (Zhang et al., 2010) comme application économique. Un réseau *feed-forward* à trois couches est utilisé pour classer la probabilité d'une récession économique

Le composant le plus fondamental d'un réseau neuronal est le neurone (Rumelhart et al., 1986). Si l'on se réfère à la figure 3 , une neurone reçoit un certain nombre d'entrées x_m .

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

L'entrée multiplié par un poids w_{km} reliant l'entrée à une fonction de sommation. Un biais est ajouté ici, (b_k).

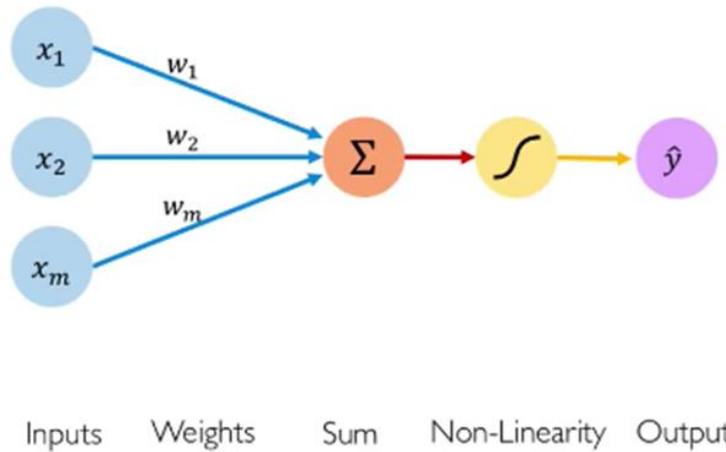


Figure 3.Représentation d'un perceptron à une seule couche

On obtient ainsi une entrée v_k qui est transmise à une fonction d'activation f .

Celle-ci produit la sortie du neurone y_k qui est envoyée au neurone suivant. La sortie d'un neurone est donc :

$$y_k = f_k(w_{x_m} + b_k)$$

m fait référence à une entrée spécifique, k au neurone spécifique dans une couche d'une neurone. v_k est un champ local qui sera plus tard rempli avec un gradient.

Les paramètres w_{km} et b_k peuvent être ajustés par le réseau selon une règle d'apprentissage, tandis que la fonction d'activation est choisie par le concepteur lors de la configuration initiale (Hagan et al., 2014).

Suivant l'analogie biologique, le poids w_{km} est la force du signal provenant d'une synapse, la fonction de sommation et d'activation est le corps du neurone, tandis que la sortie est le signal envoyé à une synapse connectée à un autre neurone.

C'est également ainsi qu'un réseau peut avoir plusieurs couches : une couche d'entrée, une couche cachée et une couche de sortie.

Avec plusieurs entrées x_m et plusieurs neurones, k , il existe plusieurs poids. Ceux-ci forment la matrice de poids, W , avec les éléments $w_1, w_2, w_3, \dots, w_{km}$:

$$W = \begin{bmatrix} w_{1,1} & \cdots & w_{1,m} \\ \vdots & \ddots & \vdots \\ w_{k,1} & \cdots & w_{k,m} \end{bmatrix}$$

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Cette matrice de poids est multipliée sur les entrées. La matrice ressemble également à un réseau simple couche à entrées multiples. La sortie de chaque neurone est donc donnée par :

$$y_k = f_k(w_{x_m}x_m + b_k)$$

Un réseau multicouche comprend une couche d'entrée, un certain nombre de couches cachées et une couche de sortie. Avec plusieurs couches cachées et une couche de sortie. k désigne les neurones de la couche située à droite des neurones i , et j à droite de la couche k , donnant l'ordre :

$$i \rightarrow k \rightarrow j$$

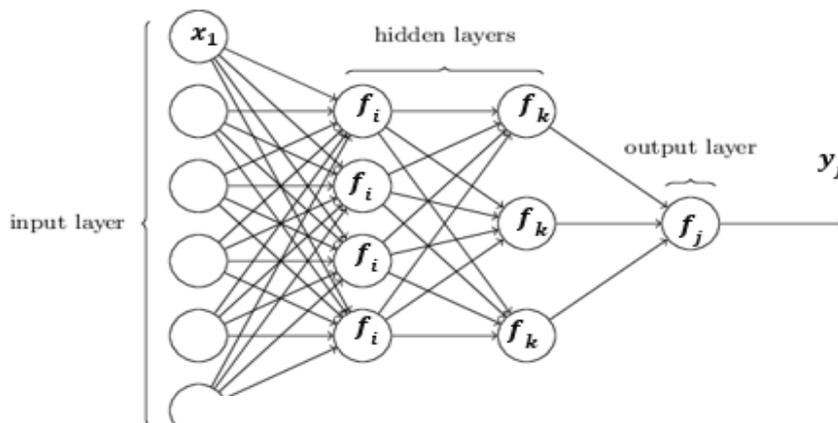


Figure 4. Perceptron multicouche

L'entrée x_m est multipliée par la matrice de poids W créant le champ local v_k en supposant une condition initiale de $b_k = 1$. Ce champ v_k est utilisé par la fonction d'activation f_k . La sortie de la fonction d'activation, y_k , est ensuite transmise à la couche suivante j , servant d'entrée à ces neurones. Pour mieux montrer le flux d'informations, la sortie y_k d'une couche cachée est appelée entrée nette de la couche suivante, notée : $net_k = y_k$

Une couche de sortie dédiée présente la sortie finale du réseau, y_j .

3.3.2 Réseaux de neurone récurrents

Les réseaux neuronaux de type *feedforwrd* sont efficaces pour de nombreux problèmes, comme la classification où les entrées se voient attribuer une classe ou une étiquette, les problèmes de régression où une quantité de valeur réelle est prédite en fonction d'un ensemble de paramètres d'entrée. Le principal problème avec ces types de réseaux est qu'ils ne se souviennent pas de ce qu'ils ont appris, c'est-à-dire qu'après chaque itération de formation du réseau, celui-ci repart à

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

zéro sans se souvenir de ce qu'il a appris lors de l'itération précédente. Cette propriété les désavantage lorsque les données sont séquentielles.

Les données séquentielles et spécifiquement les séries temporelles sont caractérisés par des points de données sont interdépendants (les données à l'instant t dépendent des données à l'instant $t-1$). De ce fait une dimension temporelle peut être ajoutée en utilisant une structure de réseau récurrent, qui facilite l'ajout d'une composante de retard à la structure du réseau (Hagan et al.,2014).

Ce réseau de neurones récurrents (RNN) est une classe de réseaux de neurones artificiels où les connexions entre les nœuds forment un graphe orienté le long d'une séquence temporelle. Cela lui permet de présenter un comportement dynamique temporel. Dérivés des réseaux de neurones prédictifs, les RNN peuvent utiliser leur état interne (mémoire) pour traiter des séquences d'entrées de longueur variable.

Le bloc de retard (delay block) dans le réseau de neurone récurrent permet aux sorties antérieures du réseau d'influencer les sorties futures et ouvre ainsi la voie à la possibilité de **dépendances décalées** dans les données économiques.

De cette façon, le réseau récurrent apprend non seulement des modèles dans la mise en correspondance des entrées et des sorties, mais aussi comment les modèles antérieurs affectent les modèles actuels. La matrice de poids est alors essentiellement une matrice de chargement semblable à celle utilisée dans le modèle de facteur dynamique.

Les fonctions d'activation :

La commutation "on/off" des neurones dans l'analogie biologique est imitée par les fonctions d'activation dans le réseau artificiel. Ces fonctions sont essentielles au fonctionnement des réseaux car elles agissent comme des portes déterminant l'activité d'un neurone.

Elles sont ajoutées à un réseau neuronal artificiel afin d'aider le réseau à apprendre des modèles complexes dans les données. Si l'on compare avec un modèle basé sur les neurones qui se trouve dans notre cerveau, la fonction d'activation décide à la fin de ce qui doit être envoyé au neurone suivant. C'est exactement ce que fait une fonction d'activation dans un ANN également.

Elle prend le signal de sortie de la cellule précédente et le convertit en une forme qui peut être utilisée comme entrée pour la cellule suivante. La comparaison peut être résumée dans la figure ci-dessous :

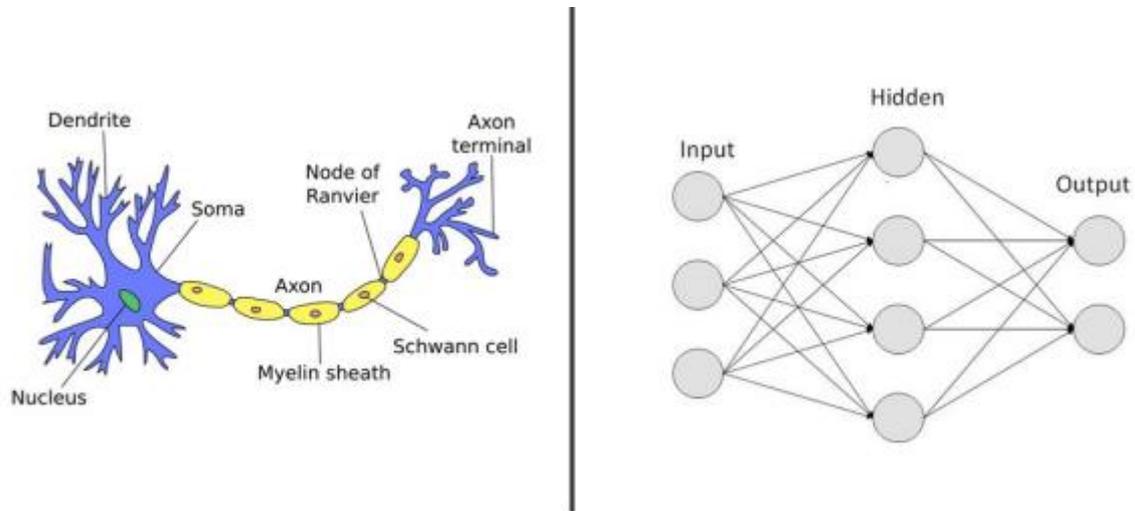


Figure 5. Graphique de neurone biologique (gauche) et réseau de neurones artificiels (droite) (source : Ghallou , 2017)

Il existe différentes fonctions d'activation, et différentes fonctions sont utiles pour différentes applications.

En général, il existe trois catégories de base : les fonctions à seuil, les fonctions linéaires par morceaux et les fonctions sigmoïdes (Haykin, 1999).

La rétropropagation du gradient :

Dans le domaine de l'apprentissage statistique, la **rétropropagation du gradient** (*backpropagation*) est une méthode qui vise à calculer le gradient de l'erreur pour chaque neurone d'un réseau de neurones, partant de la dernière couche vers la première.

La technique repose sur la correction des erreurs selon l'importance de la contribution de chaque élément aux erreurs (les poids synaptiques dans le cas des réseaux de neurones).

Par le biais des itérations, le but de l'algorithme est de converger vers une configuration optimale des poids synaptiques. Cet état peut être un minimum local de la fonction, ou, idéalement, le minimum global de cette fonction de coût.

L'algorithme de rétropropagation et la descente de gradient disposent certaines caractéristiques importantes :

- **Fonction d'activation** : La fonction d'activation doit être différentiable et doit être comprise entre $[0, 1]$ entraînent des ajustements toujours plus importants des poids, ce qui provoque la saturation du gradient. Les fonctions d'activation antisymétriques, comme la

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

tangente hyperbolique $[-1, 1]$, et les poids initiaux aléatoires autour de la moyenne de la fonction, résolvent ce problème dans une certaine mesure. La tangente hyperbolique a montré de bonnes performances dans différentes structures récurrentes dans la littérature (Glorot & Bengio, 2010).

- **Saturation du gradient** : Le problème saturation du gradient est un exemple de comportement instable que vous pouvez rencontrer lors de la formation d'un réseau neuronal profond.

Il décrit la situation dans laquelle un réseau multicouche *feed-forward* profond ou un réseau neuronal récurrent est incapable de propager des informations de gradient utiles de l'extrémité de sortie du réseau de neurone vers les couches proches de l'extrémité d'entrée du modèle.

Il en résulte l'incapacité générale des modèles à plusieurs couches à apprendre sur un ensemble de données donné, ou l'incapacité des modèles à plusieurs couches à converger prématurément vers une mauvaise solution.

- **Sur-ajustement (Overfitting)** : Le surajustement ou surapprentissage intervient lorsque l'algorithme sur-apprend c'est à dire lorsqu'il apprend à partir des données mais aussi à partir de patterns (structures et schémas) qui ne sont pas liés au problème, comme du bruit.

Ainsi, le surapprentissage est lié à une erreur de type variance très élevée. Ce problème se manifeste généralement quand des modèles très complexes.

Dans le cas des réseaux de neurone, le modèle se concentre essentiellement sur l'apprentissage des données d'entraînement, mais oublie que les entrées peuvent prendre d'autres valeurs que celles présentées. Le réseau devient trop confiant dans sa capacité à tout expliquer, sur la base des données d'apprentissage. Lorsqu'on lui présente des valeurs d'entrée jamais vues auparavant, il essaie d'adapter la nouvelle valeur à quelque chose de similaire qu'il connaît déjà, ce qui entraîne souvent de mauvaises prédictions de sortie (Mitchell, 1997).

La solution la plus utilisée pour limiter ce problème est la technique de régularisation qui permet de réduire l'erreur de type variance.

- **Minimum local** : Avec les fonctions d'activation non linéaires, le gradient d'erreur peut avoir plusieurs minimums. Cela pose un problème lorsque les poids sont initialisés de manière aléatoire, car le minimum le plus proche vers lequel converge le poids peut n'être que local et non global. Cela donne une prédiction, mais pas nécessairement la plus précise.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Des cycles d'entraînement identiques produisent des prédictions différentes, le point de départ étant la seule différence. L'utilisation de l'erreur instantanée et de l'erreur instantanée moyenne dans l'algorithme de rétropropagation le rend stochastique par nature. La moyenne de tous les gradients individuels de tous les échantillons d'entraînement limite quelque peu l'ampleur du bruit des gradients locaux (Mitchell, 1997).

- **Gradients disparaissant ou explosant** : Ce phénomène est souvent rencontré dans les réseaux récurrents non linéaires. Ceci est dû au fait que le réseau a du mal à apprendre les dépendances à long terme et se limite à la mémoire à court terme. Principalement c'est à cause du gradient multiplicatif qui s'accroît /décroit exponentiellement en fonction du nombre de couche de réseau de neurone (Hochreiter & Schmidhuber, 1997).

3.3.3. Le LSTM : un RNN amélioré

L'intuition sous-jacente derrière l'algorithme LSTM :

Introduits par Hochreiter et Schmidhuber (1997) et étendus par Graves et al. (2008) et Cho et al. (2014), le réseau de neurones **Long Short Term Memory (LSTM)** est un cas particulier du réseau de neurones récurrent qui est capable de capturer les relations à long terme dans des séries temporelles.

En effet, les RNN ne prennent en compte que des dépendances très court terme. C'est pour remédier à ce problème qu'a été introduit en 1997 le modèle LSTM. Les RNN souffrent du problème de la disparition du gradient (*vanishing gradient*) ce qui entrave l'apprentissage de longues séquences de données. Les gradients contiennent les informations utilisées dans la mise à jour des paramètres RNN. Lorsque les gradients deviennent de plus en plus petits, les mises à jour des paramètres deviennent non significatives, ce qui signifie qu'aucun véritable apprentissage n'est effectué.

Les modèles LSTM ont la capacité de résoudre un autre problème, à savoir les données à fréquence mixte.

Ainsi, les données de fréquence mixte peuvent être alimentées au réseau dans la plus haute fréquence disponible, les données de fréquence inférieure ayant des manques à des périodes où les données ne sont pas publiées. Ces données manquantes peuvent ensuite être remplies à l'aide de diverses approches, notamment avec la moyenne, la médiane, avec des valeurs échantillonnées à partir d'une distribution (Ennett et al., 2001), ou avec d'autres méthodes plus complexes (Smieja et al., 2019).

Par conséquent, les réseaux LSTM pourraient être des candidats appropriés pour modéliser ce type de dépendance dans les séries temporelles, ce qui justifie leur utilisation pour la prévision

de l'inflation et, par conséquent, explique pourquoi ils sont l'un des modèles examinés dans le présent travail.

Fischer et Krauss (2018), Essien et Giannetti (2019), et Wang, Qi et Liu (2019) deviennent des références précieuses, démontrant les utilisations des réseaux LSTM pour les séries chronologiques, qui peuvent être immédiatement adaptés à la prévision de l'inflation.

L'architecture de LSTM :

L'architecture des **LSTM** est bien adaptée à la capture des dépendances temporelles dans les données. Ces algorithmes introduisent une cellule mémoire et trois portes : une porte d'entrée, une porte de sortie et une porte d'oubli (Chung et al., 2014). Cette architecture permet aux gradients de circuler de manière inchangée dans le réseau, ce qui atténue le problème de gradient évanescent des RNN et les rend plus adaptés à l'application au problème de la prévision des séries temporelles.

L'ajout de la dimension temporelle permet au modèle d'être entraîné sur des décalages multiples de chaque variable, plutôt que sur des observations contemporaines.

L'idée derrière ce choix d'architecture de réseaux de neurones est de diviser le signal entre ce qui est important à court terme à travers le **hidden state** (analogue à la sortie d'une cellule de RNN simple), et ce qui l'est à long terme, à travers le **cell state**, qui sera explicité plus bas. Ainsi, le fonctionnement global d'un LSTM peut se résumer en 3 étapes :

- Détecter les informations pertinentes venant du passé, piochées dans le cell state à travers la porte d'oubli (**forget gate**) ;
- Choisir, à partir de l'entrée courante, celles qui seront pertinentes à *long terme*, via la porte d'entrée (**input gate**). Celles-ci seront ajoutées au cell state qui fait office de mémoire longue ;
- Piocher dans le nouveau **cell state** les informations importantes à *court terme* pour générer le hidden state suivant à travers l'**output gate**.

4. L'utilisation des techniques de Machine Learning dans la prévision de l'inflation

En macroéconomie, à laquelle appartient le problème de la prévision de l'inflation, les applications de l'apprentissage automatique sont en plein essor.

Medeiros et al., ont été parmi les premiers auteurs à étudier en profondeur les modèles d'apprentissage automatique pour la prévision de l'inflation sur plusieurs périodes, et en les comparant en termes de performances hors échantillon.

Moshiri et Cameron (2000), ont comparé les performances des modèles de réseaux neuronaux artificiels à rétropropagation aux approches économétriques traditionnelles (modèle structurel de forme réduite, modèle ARIMA, modèle vectoriel autorégressif et modèle vectoriel bayésien) pour la prévision hors échantillon du taux d'inflation au Canada. Les résultats montrent que les modèles hybrides peuvent prévoir aussi bien que toutes les méthodes économétriques traditionnelles et les surpassent dans certains cas.

Un autre exemple est un travail de Nakamura (2005), où les réseaux neuronaux surperforment les approches traditionnelles.

Choudhary et Haider (2012) testent les modèles ANN contre un modèle autorégressif pour les taux d'inflation mensuels de 28 pays de l'OCDE et concluent que les modèles ANN surperforment le benchmark pour 45% des pays de l'échantillon, tandis que le modèle autorégressif n'a été supérieur que dans 23%.

Les combinaisons des modèles différents de réseaux neuronaux ont également donné des résultats prometteurs.

Kock et Terasvirta (2016) analysent l'utilisation de réseaux neuronaux artificiels pour la prévision de l'inflation en Finlande en utilisant des modèles linéaires autorégressifs et non linéaires de réseaux de neurones.

Dans ce cas, le réseau neuronal feed-forward avec l'algorithme de formation par rétropropagation est plus performant que le modèle ARIMA. La conclusion est faite après l'analyse de RMSE.

Kapetanios et al. (2016) ont testé les performances des méthodes de ML pour la prévision de l'inflation dans les pays de zone euro. Ils ont analysé notamment leur rôle dans la sélection/réduction de variables macroéconomiques déterminantes de l'inflation.

Dans le cas du Royaume-Uni, Chakraborty et Joseph (2017) ont comparé les performances des différentes techniques de ML et des modèles autorégressifs en utilisant plusieurs variables macroéconomiques sur la période 1988-2015.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Ils ont conclu que toutes ces techniques fournissent de meilleures prévisions que les modèles autorégressifs de référence. De même Garcia et al. (2017) ainsi que Baybuza (2018) ont conclu que les techniques d'apprentissage automatique sont plus performantes que les modèles autorégressifs et de marche aléatoire. En outre, ils ont suggéré que leur performance prédictive diffère dans divers horizons de prévision de l'inflation.

Almosova et Andresen (2019) démontrent l'intérêt des techniques d'apprentissage automatique non linéaires pour la prévision des séries temporelles macroéconomiques et montrent qu'un réseau neuronal récurrent à mémoire à long terme (LSTM) surpasse le modèle autorégressif linéaire (AR), le modèle de marche aléatoire (RW), le modèle autorégressif saisonnier (SARIMA), le modèle de commutation de Markov et le réseau neuronal simple entièrement connecté (NN) pour prévoir l'inflation mensuelle de l'IPC américain.

Ouerghi et al. (2019), ont utilisées un modèle de ML combiné avec un modèle autorégressif pour la prévision de l'inflation en Tunisie sur la période 2000-2017. Ils ont conclu que la combinaison des prévisions semble fournir de meilleures prédictions. Ils ont également montré que les réserves de change des banques commerciales, les agrégats monétaires et l'indice des prix des matières premières sont les mesures les plus prédictives de l'inflation.

La littérature ne comprend pas plusieurs exemples d'exercice de prévision de l'inflation en Tunisie à l'aide des techniques d'apprentissage automatique. Dans ce contexte, la littérature appelle à des études portant sur les performances de ces techniques pour la prévision de l'inflation pour l'économie tunisienne

Dans une étude plus récente sur une économie émergente, Rodriguez-Vargas (2020) a noté que l'intégration de modèles d'apprentissage automatique produit de meilleurs résultats que les modèles de prédiction univariés à tous les horizons.

Paranhos (2021) a montré que le LSTM, est plus performant que le réseau feed-forward traditionnel dans la prévision de l'inflation américaine pour les horizons longs, ce qui suggère un avantage du modèle récurrent dans la capture de l'information macroéconomique à long terme.

Medeiros et al. (2021) ont récemment fourni des preuves soutenant le rôle des techniques de ML dans la prévision de l'inflation dans l'économie américaine. Ils ont fait valoir que le modèle de forêt aléatoire (Random forest) est celui qui produit de meilleurs résultats en raison des non-linéarités potentielles détectées dans la relation entre les indicateurs macroéconomiques et le taux d'inflation.

Ils affichent également une stabilité remarquable sur différents horizons, fournissant des résultats convaincants dans les périodes d'expansion et de récession économiques, ainsi que dans les périodes de crise de forte incertitude.

5. Le langage de programmation de Machine Learning & les bibliothèques clé

Dans le domaine de Machine Learning, plusieurs langages de programmation sont utilisés pour la conception des algorithmes comme : Python, Java, C++, R, & Julia.

Le langage de programmation Python s'est rapidement imposé, au cours de ces dernières années, comme le choix incontournable et le langage de référence absolue pour la conception des algorithmes de ML et exploiter le potentiel grandissant du Big Data.

Le gain de popularité dont bénéficie ce langage s'explique en grande partie par les nombreuses possibilités offertes par ses puissantes bibliothèques et outils "Open source" qui offrent des fonctionnalités flexibles pour : les calculs scientifiques et les analyses numériques (Numpy, Scipy, Pandas), les visualisations de données (Matplotlib) ainsi que la Machine Learning (Scikit-learn, Tensor-Flow).

De plus, parmi les importants atouts du système Python est sa portabilité ou encore sa capacité à fonctionner sur différentes plates-formes. L'avantage de cette portabilité est qu'elle offre la possibilité d'exécuter le même code sous différents environnements techniques.

Par ailleurs l'utilisation de ce système est adaptée à l'intégration de composants écrites dans d'autres langages de programmation tels que *C*, *C++* ou *Java* sans aucune réadaptation requise. Les bibliothèques sont des programmes et des ensembles de fonctions écrits dans un langage spécifique qui aident les utilisateurs de langage de programmation à effectuer diverses tâches. Les algorithmes d'apprentissage statistique nécessitent un environnement bien testé et bien structuré qui permet d'exécuter des solutions de codage de la meilleure qualité.

Il existe de nombreuses bibliothèques Python pour l'intelligence artificielle et l'apprentissage automatique. Les modules fournis par ces bibliothèques permettent d'accéder aux diverses fonctionnalités du système. En outre, les modules écrits en Python apportent des solutions aux problèmes de programmation courants. Pour minimiser le temps d'exécution des algorithmes, Python offre un programme pré-écrit, prêt à être utilisé pour les tâches de codage courantes (Beklemysheva ,2020).

Dans cette partie, nous allons exposer les bibliothèques clés utilisés par la communauté scientifique pour une implémentation réussie des algorithmes de Machine Learning :

Figure 6. Meilleures bibliothèques Python pour l'apprentissage statistique et l'apprentissage profond



Tensorflow :

C'est un outil d'apprentissage automatique « Open Source », rapide, flexible et évolutif.

Il a été développé par l'équipe *Google Brain*⁹ et est utilisé dans presque toutes les applications Google pour l'apprentissage automatique. Il offre des fonctionnalités très développées pour la conception surtout des algorithmes de *Deep Learning*. De plus, l'accessibilité de la syntaxe qu'il offre rend les ressources de programmation simples à manipuler. L'application de Machine Learning de TensorFlow la plus utilisée est les réseaux neuronaux. Notamment, il est doté d'une interface pour Python ainsi que R.

NumPy :

C'est une bibliothèque de gestion de données multidimensionnelles étendues et de fonctions mathématiques complexes qui opèrent sur les données. Son atout majeur est qu'elle offre un calcul et une exécution très rapides de fonctions compliquées travaillant sur des tableaux. Et elle est très populaire parmi la communauté scientifique.

Parmi les fonctionnalités fournies par Numpy :

- L'algèbre linéaire de base et opérations statistiques ;
- La prise en charge des opérations mathématiques et des fonctions logiques ;
- Les fonctions de tri et de sélection ;
- Les simulations aléatoires ;
- La manipulation des tableaux à n dimensions.

⁹ Google Brain est un projet de recherche d'apprentissage profond (Deep Learning) conduit par Google.

Keras :

C'est l'une des bibliothèques les plus populaires pour Python. Initialement conçu par Google dans le cadre du projet « Open-Ended Neuro Electronic Intelligent Robot Operating System » (ONEIROS), Keras permet une expérimentation rapide avec l'algorithme de réseaux de neurones profonds. Elle se concentre essentiellement sur son ergonomie, sa modularité et ses capacités d'extension. Keras est populaire dans le domaine de l'apprentissage profond et a été utilisée par des chercheurs de grandes organisations scientifiques, comme la NASA et le CERN.

Scikit-learn :

C'est une autre bibliothèque d'apprentissage machine activement utilisée pour Python. Développé par des instituts français de recherche et d'enseignement supérieur, elle fournit une intégration facile avec plusieurs bibliothèques de ML telles que NumPy et Pandas. De plus, Scikit-learn est livré avec le support de divers algorithmes de ML tels que : les algorithmes de classification, Clustering, régression, réduction de dimensionnalité, sélection du modèle et prétraitement. Construit autour de l'idée de la facilité d'utilisation tout en restant flexible, Scikit-learn se spécialise dans la modélisation et pas le chargement, la manipulation ou la visualisation des données.

Pandas :

C'est une bibliothèque Python et est principalement utilisée pour la manipulation et l'analyse de données. Les pandas facilitent le travail avec des séries temporelles et des données multidimensionnelles structurées pour l'implémentation des algorithmes d'apprentissage automatique. Parmi les fonctionnalités intéressantes de la bibliothèque Pandas en matière de gestion des données :

- Le traitement des données manquantes et l'alignement des données ;
- Les fusions et les jonctions d'ensembles de données ;
- Les options de filtrage des données.

Les pandas **utilisent** « **DataFrames** », qui est un terme technique désignant une représentation bidimensionnelle des données avec des fonctionnalités spécifiques.

Matplotlib :

C'est une bibliothèque Python destinée essentiellement à la visualisation des données sous forme de graphiques statiques, animées et interactives. Elle peut être combinée avec d'autres bibliothèques Python de calcul scientifique.

Section 3 : L'économétrie & les techniques de Machine Learning

Selon Morgan (1990), l'utilisation de techniques quantitatives en économie remonte au 16ème siècle. Mais il faudra attendre le début du XXIème siècle pour que le terme « économétrie » soit utilisé pour la première fois, donnant naissance à "*l'Econometric Society*" en 1933. Les techniques d'apprentissage machine sont plus récentes.

Si les deux disciplines ont évolué en parallèle, l'émergence des données massives impose de créer des passerelles entre les deux communautés, en rapprochant les « deux cultures » (Breiman,2001), opposant la statistique mathématique (une des limites de l'économétrie traditionnelle, selon Aldrich,2010) à la statistique computationnelle, et à l'apprentissage statistique de manière générale.

Deux orientations principales se dégagent de la discussion sur l'apprentissage automatique et l'économétrie : l'économétrie par rapport à l'apprentissage automatique, et l'économétrie combinée à l'apprentissage automatique.

1. L'économétrie Versus le Machine Learning

Dans cette section du chapitre, nous allons développer les principales différences entre l'apprentissage automatique et les travaux empiriques conventionnels en économie ou l'économétrie.

Historiquement, l'apprentissage automatique et l'économétrie semblent avoir une finalité en commun. Les deux domaines font appel à des techniques similaires pour résoudre des problèmes de prédiction (par exemple, la régression logistique), bien qu'avec un langage et un jargon complètement différent.

Néanmoins, si les « deux cultures » (ou les deux écoles) de l'économétrie et de l'apprentissage statistique se sont développées et évoluées en parallèle, le nombre de passerelles entre les deux ne cesse d'augmenter.

Pour commencer, il faut noter qu'il existe déjà une différence historique entre les deux disciplines (Boelaert & Ollion, 2018) : Contrairement aux statistiques traditionnelles, les techniques de ML s'appuient fortement sur la puissance de calcul. Cette différence s'explique par le fait que les modèles économétriques ont été développées à une époque où la puissance

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

de calcul n'était pas si courante. Cela a bien sûr des conséquences énormes sur le développement des deux disciplines

La principale différence entre l'économétrie et l'apprentissage automatique réside dans l'approche adoptée pour la formulation et compréhension d'un problème.

Les économètres visent à la construction des modèles probabilistes qui permettent de créer des **relations causales** (quantifier les causes et les effets) entre différents phénomènes économiques qui intéressent les décideurs de la politique économique. Leur travail se base sur l'examen des coefficients et la conception des hypothèses ainsi que des expériences pour les tester.

Et c'est la méthode statistique qui a beaucoup plus d'importance que les techniques de calcul.

Les praticiens de Machine Learning quant à eux, utilisent des algorithmes qui vont apprendre de leur erreur en essayant de faire la meilleure précision prédictive.

Ce qui signifie que nous voulons que l'algorithme de ML soit aussi performant que possible lorsqu'il est appliqué à des données nouvelles. Cela veut dire que dans l'apprentissage automatique nous accordons moins d'attention à l'incertitude statistique et aux erreurs standard, et plus d'attention à l'incertitude du modèle.

Un autre point de divergence consiste au fait que l'économétrie depuis sa genèse s'appuie sur de lourdes hypothèses sur les données et leurs distributions. En revanche, les modèles de ML sont moins exigeants en termes d'hypothèses initiales et il y a une certaine liberté dans la recherche de la solution et celle-ci est souvent basée sur l'apprentissage supervisé. Et pour l'apprentissage supervisé, des données massives sont nécessaires et pas nécessairement beaucoup de connaissances préalables.

Au contraire, dans les techniques de ML, la qualité prédictive du modèle constitue un indicateur de performance clé. Le but principal alors est d'obtenir une erreur de généralisation aussi faible que possible, ce qui signifie que nous voulons que l'algorithme de ML soit aussi performant que possible lorsqu'il est appliqué à des données nouvelles. Cela veut dire que dans l'apprentissage automatique nous accordons moins d'attention à l'incertitude statistique et aux erreurs standard, et plus d'attention à l'incertitude du modèle.

Une autre piste de différence concerne le fait que l'économétrie explore le plus souvent des relations linéaires. En revanche, les relations linéaires sont rarement trouvées dans la ML (Zheng et al., 2017).

Les algorithmes de ML plus enclines à appliquer les méthodes d'ensemble (combinaison de différents modèles en parallèle) pour améliorer la précision de la prévision.

Outre les distinctions fondées sur les applications des deux, il y a également une distinction basée sur la spécification du modèle (Woloszko, 2017).

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

L'économétrie est basée souvent sur un modèle fondé sur la théorie : Les économètres dans les banques centrales commencent par une théorie du fonctionnement des phénomènes économiques et utilisent les données pour le calibrage du modèle. Les causalités sont testées à l'aide de la théorie statistique. Ensuite, ils estiment le modèle sur l'ensemble des données et par la suite les intervalles de confiance pour les paramètres estimés sont déterminés.

L'accent est mis sur les effets estimés plutôt que sur la qualité de l'ajustement du modèle.

Tout ce que les praticiens ne sont pas en mesure d'expliquer (c'est-à-dire les paramètres non significatifs) est placé dans les résidus.

Ils s'efforcent d'obtenir un modèle interprétable avec uniquement des paramètres significatifs.

Toutefois, parmi les inconvénients majeurs de ces approches économétriques qu'elles ne sont pas capables de traiter des quantités massives de données (Big Data).

Il faut noter que certains modèles économétriques tel que VAR sont athéoriques et gourmands en termes de données.

Pour l'apprentissage automatique, la philosophie diffère : les algorithmes sont censés "laisser parler les données". Ce signifie que nous laissons les algorithmes découvrir des modèles cachés dans les données. Ces modèles peuvent même ne pas encore être soutenus par une théorie. Ainsi, la puissance de ML permet l'exploitation des données massives.

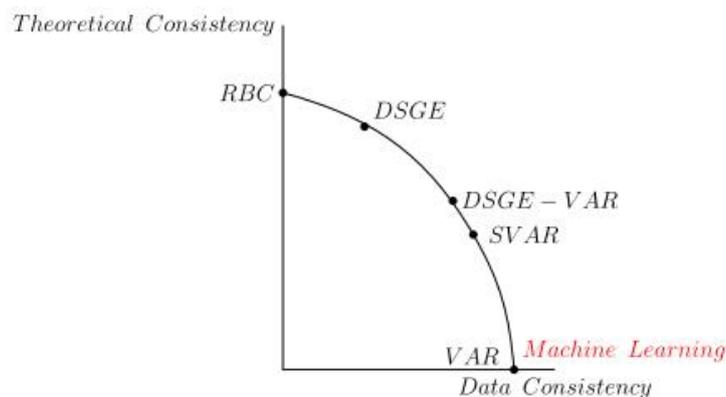


Figure 7. La frontière de Pagan

On pourrait également considérer ce graphique comme les préférences des décideurs ou des chercheurs entre les approches fondées sur la théorie et celles fondées sur les données :

De cette façon, les modèles Machine Learning et l'économétrie sont parfaitement complémentaires au lieu d'être des substituts l'un de l'autre.

Dans ce contexte, une compréhension de ce que sont ces deux disciplines, ce qui les oppose et surtout ce qui les rapproche, aide à une meilleure exploitation des outils développés par la

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

communauté de l'apprentissage automatique pour les intégrer dans des modèles économétriques et vice versa.

Dans la prochaine section, nous abordons ce que peut apporter l'apprentissage statistique à l'économétrie.

Tableau 1. Econométrie Versus Machine Learning

	Econométrie	Machine Learning
Approche	Statistique	Modèles algorithmiques
Base	Théorie économique	Data fitting
Spécialisation	Tests des hypothèses et interprétabilité des relations causales entre les variables.	Précision prédictive
Choix de modèle	<ul style="list-style-type: none"> - Significativité des paramètres - La qualité d'ajustement 	La validation croisée ou « cross validation » basée sur une technique d'échantillonnage
Point de force	Inférence causale	Prévision

Dans une étude récente du FMI, Marijn A. Bolhuis et Brett Rayner (2020) affirment que les techniques d'apprentissage automatique possèdent certaines spécificités qui permettent d'améliorer les performances des prévisions macroéconomiques par rapport aux modèles traditionnels.

Cela est dû essentiellement aux faits que les techniques conventionnelles qui sont basées sur les MCO ont du mal à surmonter plusieurs problèmes, notamment :

- **La colinéarité** : La variance de la prévision par MCO augmente en fonction du degré de corrélation entre les prédicteurs. Pour le voir, notez que la valeur attendue du produit interne (pour une covariance est élevée).
- **La dimensionnalité** : La variance de la prévision MCO augmente avec le nombre de prédicteurs K .
- **La pertinence des prédicteurs** : En relation avec la dimensionnalité, les prédicteurs non pertinents augmentent sans ambiguïté l'erreur de prévision car elles ne réduisent pas le biais, mais augmentent la variance de la prévision en augmentant $X_t'X_t$
- **La non-linéarité** : Si le *data generating process* (DGP) est non linéaire, la prévision par MCO est biaisée.

- **L'optimisation du compromis biais-variance**¹⁰(il est généralement impossible de réduire les deux termes simultanément) : Une erreur de prévision peut être décomposée en un biais et une variance (Hall, 2018).
 - Le biais d'un modèle décrit les erreurs dues à des hypothèses inexactes concernant un problème ou des données. Il s'agit de la différence entre la prédiction moyenne de notre modèle et la valeur correcte que nous essayons de prédire (Singh, 2018).
 - La variance d'un modèle décrit les erreurs dues à la sensibilité du modèle à de petites perturbations dans les données sous-jacentes.

En conséquence, même les modèles de prévision les plus sophistiqués donnent souvent lieu à des erreurs de prévision importantes, en particulier lorsque la variable à prévoir est volatile comme la croissance de la production et l'inflation dans de nombreux marchés émergents et économies en développement.

Les modèles ML se distinguent par leur capacité par rapport aux autres méthodes de prévision à mettre l'accent sur les performances hors échantillon (plutôt qu'en échantillon) et gèrent mieux les interactions non linéaires entre un grand nombre de variables. Ils sont spécifiquement conçus pour apprendre des relations complexes à partir de données passées tout en résistant à la tendance des méthodes traditionnelles à extrapoler les relations historiques dans le futur.

2. L'économétrie combinée avec les techniques de Machine Learning :

Dans la section précédente, nous avons commencé par opposer les deux approches pour comprendre leurs forces et leurs faiblesses.

Selon Hal Varian (2014), économiste chez Google, il existe plusieurs techniques d'apprentissage statistique (qu'il appelle "nouvelles astuces") que les économètres peuvent adopter dans leur modèle d'une part et les perspectives économétriques que les techniques de ML peuvent envisager.

Les fondements probabilistes de l'économétrie constituent incontestablement sa force, avec non seulement une interprétabilité efficace des modèles qui aide à la prise de décision, mais aussi une quantification de l'incertitude. Néanmoins, les performances prédictives des modèles de ML sont intéressantes, car elles permettent de mettre en avant une mauvaise spécification d'un modèle économétrique, en détectant un effet non-linéaire ou un effet croisé oublié.

¹⁰ L'un des moyens d'identifier le modèle de prévision optimal consiste à décomposer la source des erreurs de prévision en deux parties : biais & variance.

2.1 Les techniques de Machine Learning utilisées dans l'économétrie

La validation croisée ou Cross validation :

La validation croisée est une méthode d'évaluation et de comparaison des algorithmes de ML en divisant les données en deux segments : l'un utilisé pour l'apprentissage du modèle et l'autre utilisé pour la validation du modèle.

Dans une validation croisée typique, les bases d'apprentissage et de validation doivent se croiser dans des tours successifs de sorte que chaque point de données ait une chance d'être validé. La forme basique de la validation croisée est la validation croisée *k-fold*.

D'autres formes de validation croisée sont des cas particuliers de "validation croisée *k-fold*".

Dans la validation croisée à *k* fois, les données sont d'abord divisées en *k* segments ou plis de taille égale (ou presque égale). Par la suite, des *k* itérations d'apprentissage et de validation sont effectuées de telle sorte qu'à chaque itération, un pli différent des données est conservé pour la validation tandis que les $k - 1$ plis restants sont utilisés pour l'apprentissage.

Dans le cas des séries temporelles (ou chronologiques), la validation croisée n'est pas triviale. Les échantillons ne peuvent pas être choisis aléatoirement et il n'y a aucun sens d'utiliser les valeurs du futur pour prévoir les valeurs du passé car il est nécessaire de respecter la dépendance temporelle entre les observations.

La validation croisée sur "une base continue" est la méthode adéquate pour le traitement des séries temporelles. La méthode commence avec un petit sous-ensemble de données à des fins d'entraînement

Puis, s'effectue la prévision des points de données ultérieurs, ensuite la vérification de l'exactitude des points de données prévus. Les mêmes points de données prévus sont par la suite inclus dans le prochain jeu de données d'apprentissage et les points de données suivants sont prévus.

Pour rendre les choses intuitives, voici une image de la façon dont les données sont divisées dans l'approche de validation croisée "canonique" pour les modèles de séries chronologiques.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

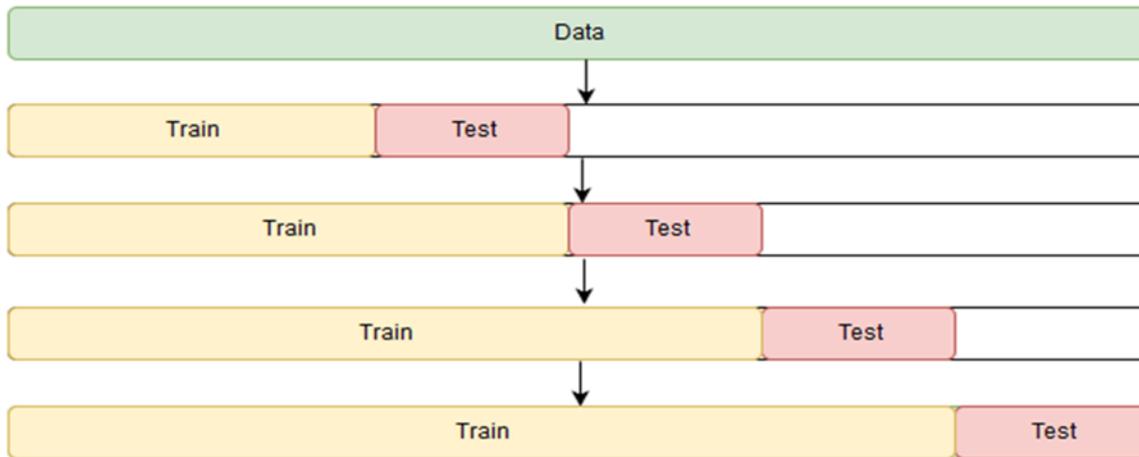


Figure 8. Une image intuitive de la façon dont les données sont divisées dans l'approche de validation croisée pour les modèles de séries chronologiques.

Les techniques de régularisation :

La régularisation est une technique clé de ML qui vise à contrôler le problème de surapprentissage (les modèles complexes ont tendance à trop bien s'adapter aux données de la base d'apprentissage mais pas aux données inconnues) en limitant l'erreur de type variance et en améliorant la généralisation de la solution pour aboutir à de meilleures performances prédictives. La technique intègre la fonction de perte pour la pénalisation un modèle comportant trop de paramètres.

Il existe plusieurs types de régularisation, qui dépendent de l'objectif recherché et des hypothèses fixées sur le problème. Certaines techniques bien connues sont la régularisation L1, L2, la régularisation "dropout" et l'Early Stopping :

- **L1 régularisation (lasso régression) :** Cette méthode de régularisation a une action préventive ayant pour but de contenir les variables du réseau dans des intervalles spécifiques, pour que celle-ci ne deviennent au cours de l'entraînement trop extrêmes. Elle ajoute une pénalité L1 qui est égale à la valeur absolue de la magnitude du coefficient, ou simplement en restreignant la taille des coefficients. Par exemple, la régression Lasso met en œuvre cette méthode.
- **L2 régularisation (ridge régression) :** Celle-ci va aussi ajouter une pénalité L2 à la fonction de perte, d'égale au carré de la magnitude des coefficients. Par exemple, la régression Ridge et les SVM mettent en œuvre cette méthode.

Pour les modèles de réseaux de neurone, les méthodes de régularisation les plus utilisées sont :

- **Le Dropout :** les poids, paramètres du réseau de neurones sont remplacés par une valeur nulle de manière aléatoire pendant l'entraînement du modèle.

- **L'Early Stopping** : L'arrêt précoce est une technique d'optimisation utilisée pour réduire l'*overfitting* sans compromettre la précision du modèle. L'idée principale de cette technique est d'arrêter l'entraînement avant qu'un modèle ne commence à s'adapter de manière excessive.

L'apprentissage ensembliste ou les méthodes d'ensemble :

L'apprentissage ensembliste est une technique spécifique du domaine de ML qui vise à améliorer la capacité de prédiction en combinant les prédictions d'un ensemble de modèles. Par exemple, elle est utilisée pour faire la moyenne des coefficients de régression de plusieurs modèles, dans le but ultime de saisir l'effet global d'une variable.

Parmi les exemples d'apprentissage ensembliste, on note : les méthodes *bagging*, *boosting* et *bootstrapping* ainsi que les méthodes de *forets aléatoires* :

Le *bagging* consiste à faire la moyenne des modèles estimés à l'aide de plusieurs échantillons *bootstrap* différents afin d'améliorer les performances d'un estimateur.

Le *boosting* implique une estimation répétée où les observations mal classées reçoivent un poids croissant à chaque répétition. La pondération augmente à chaque répétition. L'estimation finale est alors un vote ou une moyenne de l'estimation finale est alors un vote ou une moyenne de l'estimation répétée.

Les économétriciens connaissent bien le *bootstrap* mais utilisent rarement les deux autres méthodes.

Le *bagging* est principalement utile pour les modèles non linéaires tels que les arbres de décision (Friedman et Hall 2007).

Le *boosting* tend à améliorer la performance prédictive d'un estimateur de manière significative et peut être utilisé pour à peu près n'importe quel type de modèle de classification ou de régression, y compris les logits, probits, arbres, etc.

Il est également possible de combiner ces techniques et de créer une « forêt aléatoire » qui peuvent souvent améliorer de manière significative les méthodes à arbre unique.

Markov chain Monte Carlo (MCMC) :

Cette technique permet de créer des échantillons à partir d'une variable aléatoire continue dont la densité de probabilité est proportionnelle à une fonction connue. Ces échantillons peuvent être utilisés pour évaluer la valeur attendue ou la variance de cette variable.

2.2 Les techniques économétriques utilisées dans les modèles de Machine Learning

- **L'inférence causale** : Processus consistant à tirer une conclusion sur un lien de causalité sur la base des conditions d'occurrence d'un effet.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- **Les facteurs de confusion** : une variable aléatoire qui influence à la fois la variable dépendante et les variables explicatives. Ces facteurs sont notamment à l'origine de la différence entre corrélation et causalité.
- **L'expérimentation naturelle** : Une expérimentation naturelle est une étude empirique dans laquelle des individus sont exposés à des conditions expérimentales et de contrôle qui sont déterminées par la nature ou d'autres facteurs hors du contrôle des enquêteurs. La forme la plus simple est similaire à l'assignation aléatoire.

Section 4 : Une application sur des données tunisiennes

Dans cette partie, nous nous donnons pour objectif une investigation empirique avec les deux approches.

Pour cela, nous présentons au début une analyse descriptive de l'évolution de l'inflation et ses déterminants en Tunisie, sa dynamique ainsi que ses propriétés empiriques.

Ensuite, nous discutons les données et de la méthodologie d'ajustement des modèles créés pour la prévision de l'inflation et les benchmarks choisis pour l'évaluation des performances en soulignant leur mise en œuvre pour l'évaluation empirique à posteriori de la précision prédictive hors échantillon. De plus, nous exposons les langages de programmation, les bibliothèques et les fonctions requises pour les routines de calcul utilisées pour ajuster les modèles sont examinées.

Enfin, nous terminons par une conclusion pour comparer les performances des modèles de prévision de ML par rapport au benchmark.

1. L'inflation en Tunisie : une analyse descriptive

1.1 La dynamique de l'inflation en Tunisie

Durant les 20 ans pré-révolution, l'économie tunisienne était caractérisée par un niveau d'inflation modéré et inférieure en moyenne au taux d'inflation mondial.

Toutefois, après la révolution de 2011, la Tunisie a enregistré des pressions inflationnistes remarquables.

En deux ans, soit en juin 2013, le taux d'inflation s'est multiplié par deux environ enregistrant ainsi un niveau record de 6,1 % contre 3% en 2010. Ceci est expliqué selon les analystes par la politique d'assouplissement adoptée par la BCT depuis le début de période de transition de 2011 (baisse du taux directeur, baisse du taux de réserves obligatoires, injection de liquidité, etc) qui vise à relancer l'activité économique et éviter l'assèchement du crédit bancaire ("*credit crunch*"). En fait, cette explication est partielle du fait que l'inflation n'était pas d'origine monétaire uniquement.

En effet, le niveau élevé de l'inflation a accentué la pression sur les déficits jumeaux et la parité du dinar.

Pour amortir l'évolution haussière du taux d'inflation, la BCT a modéré la politique expansionniste adoptée depuis la révolution en privilégiant le resserrement graduel de la politique monétaire. De ce fait la BCT a procédé à l'augmentation de son taux directeur à quatre reprises entre 2012 et 2014.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

D'autres mesures ont été prises tel que *l'allocation intégrale* (« full allotement ») pour satisfaire les besoins des banques en termes de liquidité. En 2016, suite à la promulgation de la loi n°2016-35 le rôle de la BCT en termes de qu'entité autonome ayant pour objectif premier la « stabilité des prix » a été renforcée. Le taux d'inflation a connu une nette baisse en 2016 pour atteindre 3.7%.

En 2017, ce niveau a grimpé à 5,3% en moyenne suite à une évolution exceptionnelle des prix des produits alimentaires à cause de l'effet de la dépréciation du dinar.

En particulier, l'inflation sous-jacente s'est établie à 6,3% en moyenne en 2017 contre 5,2% en 2016 reflétant le caractère persistant de l'inflation.

En 2018, le taux d'inflation s'est accentué pour atteindre 7,3% (en moyenne). Cette accélération de l'inflation porte la marque de multiples chocs d'offre, dont ceux liés aux mesures fiscales (relèvement des taux de la TVA), l'ajustement à la hausse des prix à la pompe suite au renchérissement des prix internationaux de l'énergie, conjugués à l'effet de la dépréciation du dinar vis-à-vis des principales devises étrangères.

Après la spirale inflationniste déclenchée à partir de 2016, le taux d'inflation a connu une baisse en 2019 pour atteindre 6,7%.

La BCT a poursuivi sa politique monétaire restrictive pour faire face à l'intensification des pressions inflationnistes (augmentation du taux d'intérêt directeur de 5 reprises en 2017 et 2019). Cela a permis de diminuer l'inflation au niveau de 6,7% en moyenne en 2019 contre 7,3% 2018. Ces mesures ont contribué, également, à contourner les besoins en liquidité bancaire

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

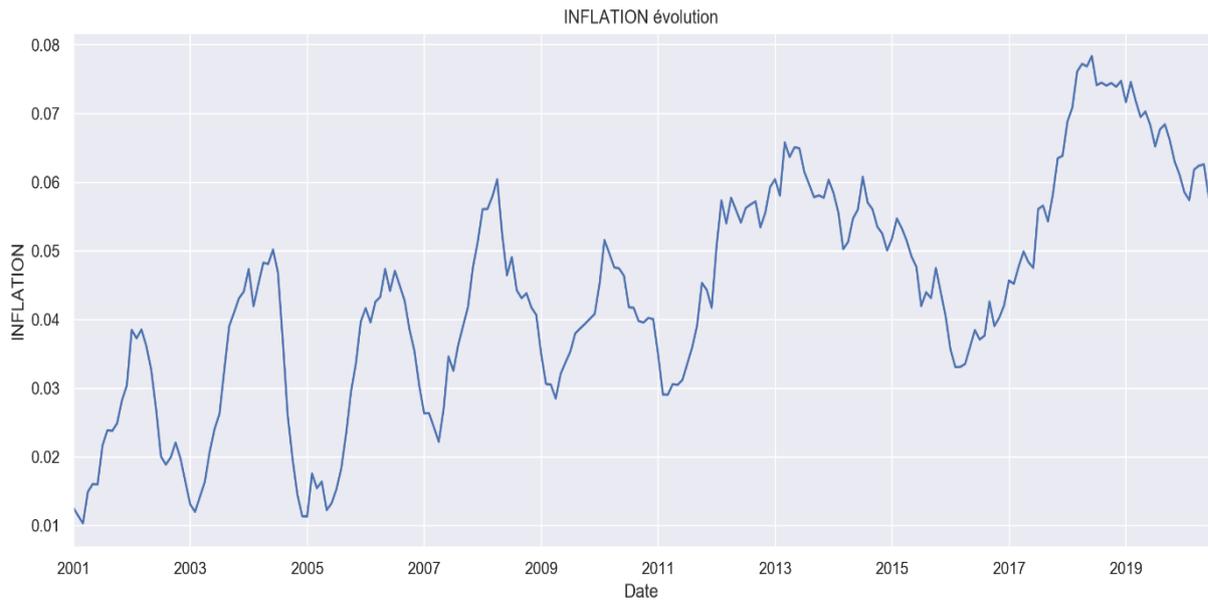


Figure 9. Evolution de l'inflation en Tunisie de 2001 à 2020

appuyé par l'effet expansif exercé par la masse monétaire en circulation et les entrées en devises.

Cette évolution favorable de l'inflation enregistrée durant 2019 était réalisée malgré la stagnation de deux de ses composantes à savoir « inflation des produits administrés » à 4,7% et la composante « inflation des produits alimentaires frais » à 8,3%.

Les premiers résultats de l'actionnement de la politique entreprise par la BCT en 2018-19 montrent la grande efficacité de ces mesures.

Notons qu'en 2018, la BCT a introduit le ratio « crédits/dépôts » ou LTD (Loan to deposit) dans la Circulaire aux Banques n°2018-10 appliqué à partir du dernier trimestre de 2018. Ce ratio a deux finalités : le contrôle de l'inflation par le biais de la masse monétaire en circulation en agissant directement sur l'offre des crédits bancaires ainsi que la liquidité.

Grâce à un resserrement plus efficace de la politique monétaire, l'inflation a enregistré une diminution, passant d'un pic de 7,7 % en juin 2018 à 5,9 % en Janvier 2020.

L'année 2020, qui aurait dû être l'année de la relance économique pour la Tunisie (suite à la décélération de l'inflation globale qui a continué au début de l'année soutenue par l'actionnement de la PM et l'appréciation du dinar contre les principales devises impactant l'inflation sous-jacente) a connu à partir du mois de mars 2020 une inflexion négative des indicateurs conjoncturels, à cause des retombées de la pandémie COVID-19, laissant présager une chute sans précédent de la croissance économique.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Contrairement aux crises précédentes, la crise liée à la pandémie est un choc exogène qui a affecté simultanément l'offre et la demande globales, induisant une forte récession de l'économie réelle.

L'impact inflationniste de la chute de l'offre, qui est de nature à augmenter le niveau des prix, a été contrebalancé par la contraction historique de la demande (restrictions sur la mobilité des personnes, télétravail, baisses des revenus, et hausse du chômage).

Ainsi, l'inflation s'est caractérisée un trend baissier en 2020 de 5,9% en janvier à 4,9% en décembre, pour s'établir en moyenne à +5,6% sur l'ensemble de l'année contre une moyenne de +6,7% enregistré durant l'année 2019.

L'apaisement des tensions inflationnistes s'explique essentiellement à la diminution de l'inflation sous-jacente des principaux groupes de produits avec des degrés différents, profitant d'une stabilité relative du taux de change du dinar, en 2020. La décélération la plus importante a concerné les prix des produits alimentaires transformés libres (la baisse importante des prix de l'huile d'olive qui résulte d'une campagne oléicole exceptionnelle). En revanche, les prix administrés ont exercé en 2020 des pressions à la hausse sur l'inflation globale.

Au mois de février 2021, l'inflation s'est stabilisée à +4,9% en glissement annuel pour le quatrième mois consécutif, contre +5,8% une année auparavant.

Cette évolution est dû à la stabilisation du rythme de progression des prix administrés (4,6%) en glissement annuel ainsi que la diminution des prix des produits alimentaires frais, dont les effets ont été partiellement compensés par la légère hausse de l'inflation sous-jacente (+5,1% après +5,0%).

En juillet 2021, le rythme de progression de l'IPC s'est accéléré pour atteindre 6.4% contre 5.7% le mois précédent.

Cette augmentation s'explique par les hausses notables des prix de certains produits frais et administrés.

Selon les récentes prévisions à moyen terme de la BCT, l'inflation s'établirait à 5,6% en 2021 et à 5,9% en 2022.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Tableau 2. Prévisions de l'inflation (moyenne annuelle)

En %	2020	2021	2022
Inflation	5,6	5,6	5,9
Inflation sous-jacente	5,6	5,5	6
Inflation des produits administrés	5,7	5,4	5,4
Inflation des aliments frais	5,9	6,4	6

Source : Périodique de conjoncture, BCT

Comme indiqué dans le tableau ci-dessus l'inflation des « produits administrés » devrait continuer à se maintenir à des niveaux élevés pour atteindre 5.9% en moyenne en 2021 et 2022. Ce niveau s'explique par l'accentuation de pression par les principaux prix administrés sur l'horizon de prévision ainsi que l'augmentation des prix internationaux des produits de base et de l'énergie.

Quant à l'inflation des produits alimentaires frais, le renforcement de la demande du secteur de l'hôtellerie et de la restauration en perspectives, la hausse des coûts des entrants et de production maintiendraient le niveau de l'inflation à la hausse.

L'inflation sous-jacente, devrait se maintenir à une trajectoire haussière graduelle sous l'effet de pressions inflationnistes des principaux déterminants. Particulièrement, ces tensions proviennent d'une part de la hausse des prix internationaux des « produits de base », des « matières premières » et de « l'énergie ». D'autre part, l'accentuation de la demande suite à la reprise des crédits à la consommation.

Selon « la note sur les évolutions économiques et monétaires et perspectives à moyen terme » de la BCT, l'incertitude de la trajectoire de l'inflation est qualifiée d'élevée et asymétrique vers le haut. Cela est expliqué par différents facteurs de risque. Principalement ces facteurs concernent l'augmentation importante et durable des prix internationaux des prix de base et/ou la détérioration des équilibres extérieurs. Notamment, les contraintes budgétaires pourraient contribuer à l'accentuation la hausse de certains prix administrés.

Ces éléments constituent un lot d'incertitude considérable à la prévision de l'inflation dans un contexte de déséquilibre macroéconomique fortement affecté par les retombées de la crise sanitaire COVID-19.

1.2 L'évolution des déterminants de l'inflation

Les prix de vente industriel :

Le ralentissement de l'inflation en 2020 a reflété le rythme de progression des différentes composantes de l'IPC.

De ce fait, l'indice des prix de vente industrielle a connu une évolution modérée de l'ordre de 2,3% en 2020 marqué par la progression de l'IPVI de différentes industries tels que : les industries chimiques et minières, les industries agroalimentaires, les industries manufacturières diverses, énergétiques ainsi que l'IPVI hors mines et industries chimiques, composante qui affecte le plus les prix à la consommation.

Tableau 3. Evolution de l'indice des prix de vente industriel (Variation en %).

Désignation	Poids en %	2018	2019	2020
Ensemble	100	7,8	6,0	2,3
Industries manufacturières	84,8	8,9	5,5	2,5
Mines	1,5	-0,3	20,6	-2,0
Energie	13,7	2,8	7,1	1,8
Hors mines et industries chimiques	84,3	6,8	5,5	4,2

Les prix à l'importation :

Les prix à l'importation ont connu, en 2020, une baisse considérable de -4,3% en moyenne, contre une -15,3% une année auparavant.

Cette baisse est dû principalement à l'effondrement des prix de l'énergie et des lubrifiants (-23%), qui s'est conjugué à la baisse des prix au niveau des industries des mines, phosphates et dérivés, celles du textile, habillement et cuirs, ainsi que les prix du secteur agricole et agroalimentaire.

Pour leur part, les prix des industries manufacturières diverses et les prix des industries mécaniques et électriques ont progressé à un rythme faible, de l'ordre de +0,9% et +1,3% (respectivement) contre et +14% et +16,4% en 2019.

Cette détente notable des prix à l'importation a induit un effet baissier sur les prix domestiques, durant l'année 2020.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Le Taux de change :

L'appréciation du dinar vis-à-vis des principales devises s'est interrompue en juin 2020 pour l'Euro et s'est poursuivie jusqu'à la fin de 2020 pour le Dollar américain, cédant la place à une légère dépréciation au cours du second semestre de l'année.

En 2020, le cours du dinar s'est apprécié de +4,3% par rapport au Dollar et de +2,4% par rapport à l'Euro en 2020 en moyenne annuelle. La bonne tenue du taux de change du dinar par rapport aux principales devises et la baisse significative des prix internationaux des produits de base (l'énergie), se sont rapidement transmises aux différentes composantes de la chaîne des prix et ont été très perceptibles au niveau des prix à la consommation, notamment des produits manufacturés, les produits alimentaires transformés libres et les prix du carburant.

Le produit intérieur brut :

Sur un autre plan, l'activité économique en berne durant l'année 2020 a ramené la croissance du PIB à un niveau historique, soit de -8,6% aux prix constants de 2010 contre +1% en 2019.

La production potentielle a été sévèrement en 2020 suite à cette contreperformance en relation avec la multitude de chocs d'offre (dégradation de la productivité et la capacité de production de plusieurs secteurs...) et de demande (contraction de la demande étrangère, hausse du chômage, dégradation du climat d'investissement...).

En 2020, l'écart de production s'est nettement creusé au vu de cet effondrement historique de l'activité, dénotant d'une absence de pressions sur les capacités de production provenant de la demande.

1.3 Les propriétés statistiques de la variable « inflation »

Dans cette section, nous décrivons les propriétés empiriques de la série chronologique de l'inflation.

L'inflation semble non stationnaire en raison de volatilité variant dans le temps. Ceci est confirmé par le test de Dickey-Fuller augmenté qui montre que la série admet une racine unitaire.

De plus, comme le montre le graphique Q-Q de la figure 10, l'hypothèse de normalité peut être immédiatement acceptée et cette conclusion peut être confirmée par un test de Jarque-Bera (on accepte l'hypothèse nulle de la distribution normale puisque la probabilité est inférieure à 5%).

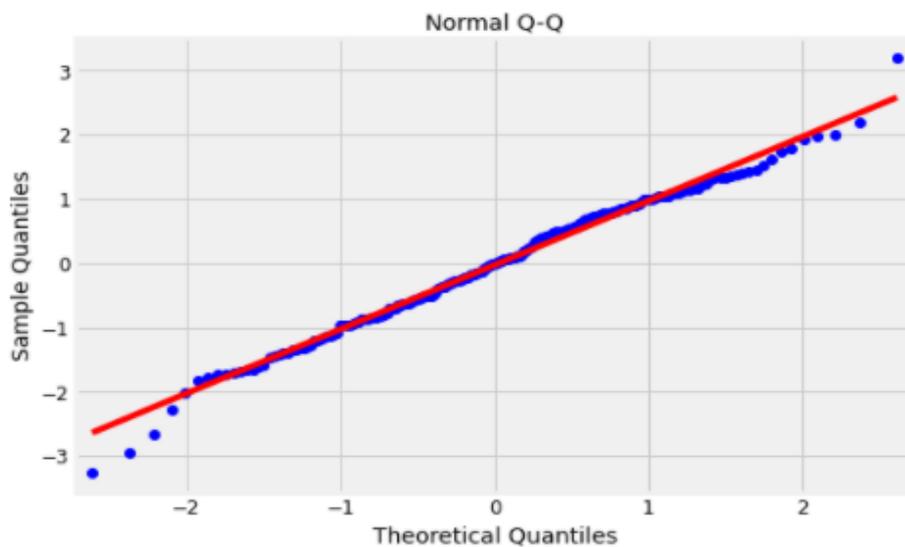


Figure 10. Le graphique Q-Q

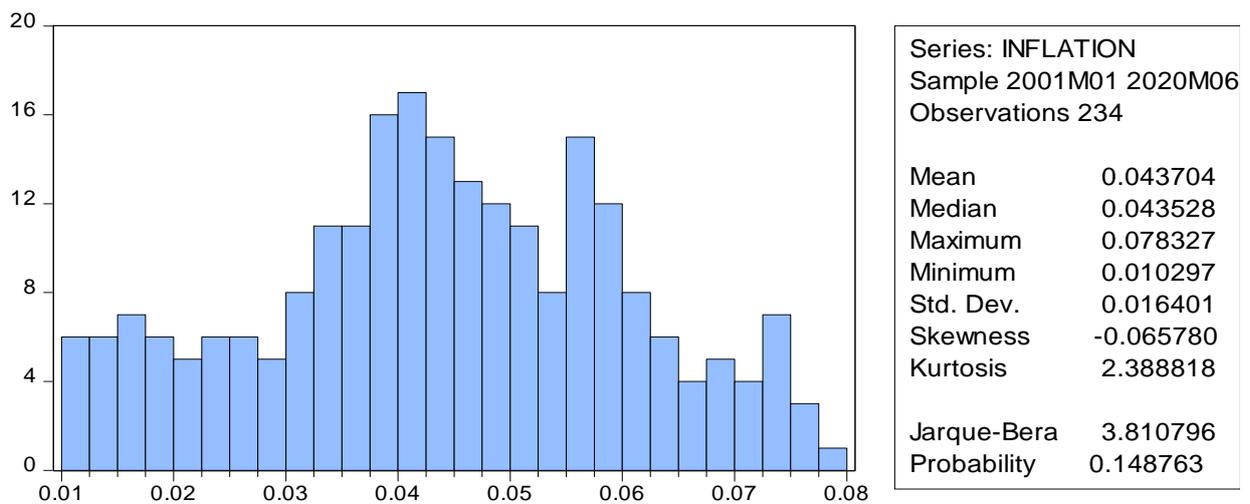


Figure 11. Histogramme relatif à l'inflation

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Les fonctions d'autocorrélation et d'autocorrélation partielle de de l'inflation sont représentées dans les figures ci-dessous. Les deux graphiques montrent que les décalages ont un pouvoir prédictif pour expliquer l'inflation actuelle.

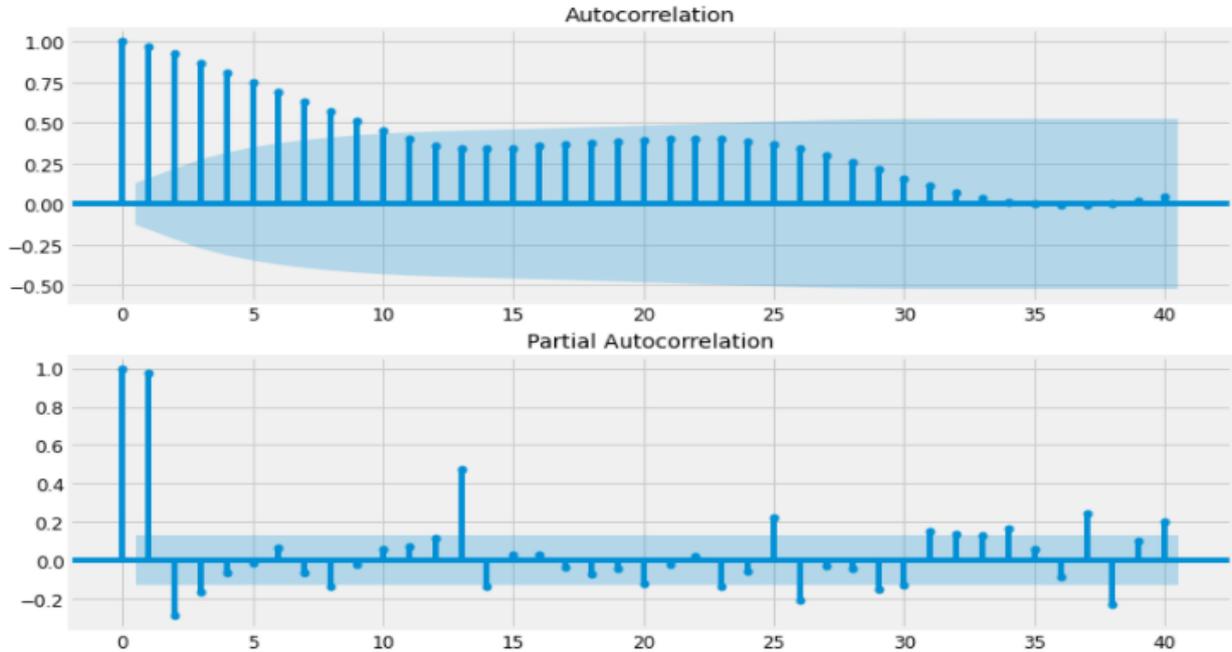


Figure 12. Les fonctions d'autocorrélation et l'autocorrélation partielle de l'inflation

On a effectué des tests pour vérifier la normalité de l'IPC. On en déduit que la série de l'IPC ne suit pas la normale.

Tableau 4. Test de normalité

Method	Value	Adj. Value	Probability
Lilliefors (D)	0.104840	NA	0.0000
Cramer-von Mises (W2)	0.530249	0.531682	0.0000
Watson (U2)	0.464892	0.466148	0.0000
Anderson-Darling (A2)	3.664015	3.679110	0.0000

2. Les variables de la base de données

Nous utilisons des séries chronologiques macroéconomiques et financières pour prévoir l'inflation en Tunisie en se référant à la littérature.

Les données historiques utilisées pour la prévision sont de fréquence mensuelle (de 2001 à 2020) et sont fournies par la BCT et l'institut national des statistiques. Sachant que d'autres séries comme la PIB ont été mensualisés.

La prévision dans cette étude concerne un horizon de CT, soit 12 mois (de 30/06/2019 à 30/06/2020) :

- L'inflation : est l'augmentation générale et durable des prix qui se traduit par la baisse de la valeur de la monnaie ;
- Le PIB : c'est un indicateur qui mesure, pour une période donnée et un pays donné, la valeur totale de la richesse produite (la production économique intérieure). Sa variation entre une période et la précédente mesure le taux de croissance économique ;
- Le taux moyen mensuel de marché monétaire (TMM) : il s'agit d'un taux calculé mensuellement d'après les différents taux interbancaires. Et il sert de référence pour les établissements de crédit pour la détermination des taux débiteurs et créditeurs appliqués aux agents économiques.
- L'agrégat monétaire M3 : Cet agrégat comprend la monnaie et les billets en circulation (BMC), les dépôts à vue, les OPCVM monétaires comme la SICAV, les comptes d'épargne des résidents, les instruments du marché monétaire et les titres de créance d'échéance 2 ans etc ;
- Les exportations et les importations réelles ;
- Le cours de l'Euro et du Dollar Américain ;
- Le cours du pétrole : Brent

Tout en s'inspirant de la méthode utilisée par la BCT et pour garantir un certain ajustement et une normalisation des séries temporelles dans le temps, nous avons procédé à la transformation logarithmique des variables utilisées.

Pour mieux comprendre la relation de l'inflation avec ses déterminants, nous effectuons une analyse bi-variée de chacune des variables sélectionnées avec l'inflation à l'aide de la fonction "scatter" sur Python. Les résultats obtenus sont les suivants :

Pour toutes les variables de l'étude, nous remarquons que l'allure des nuages de point renseigne sur l'existence d'une relation linéaire positive avec l'inflation.

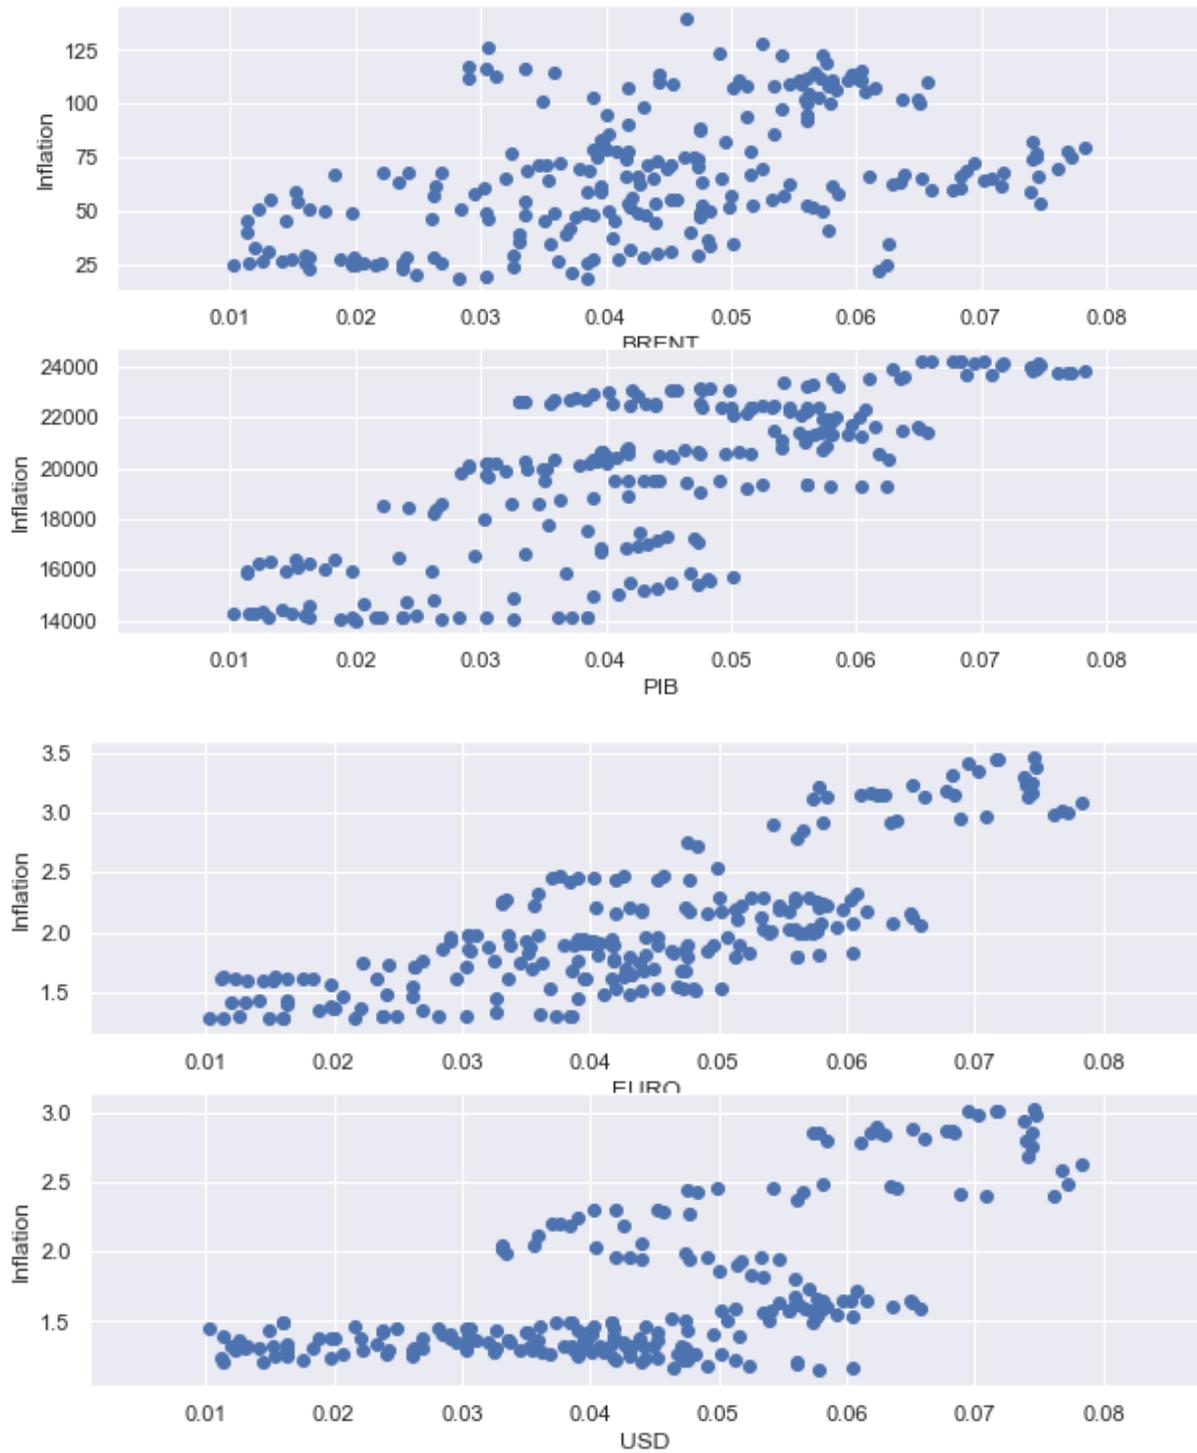
Le nuage du point de variable BRENT représente la dispersion la plus élevée.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Toutefois, pour la variable « TMM », la relation semble faire intervenir d'autres variables car elle présente une allure non linéaire :



PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES



PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

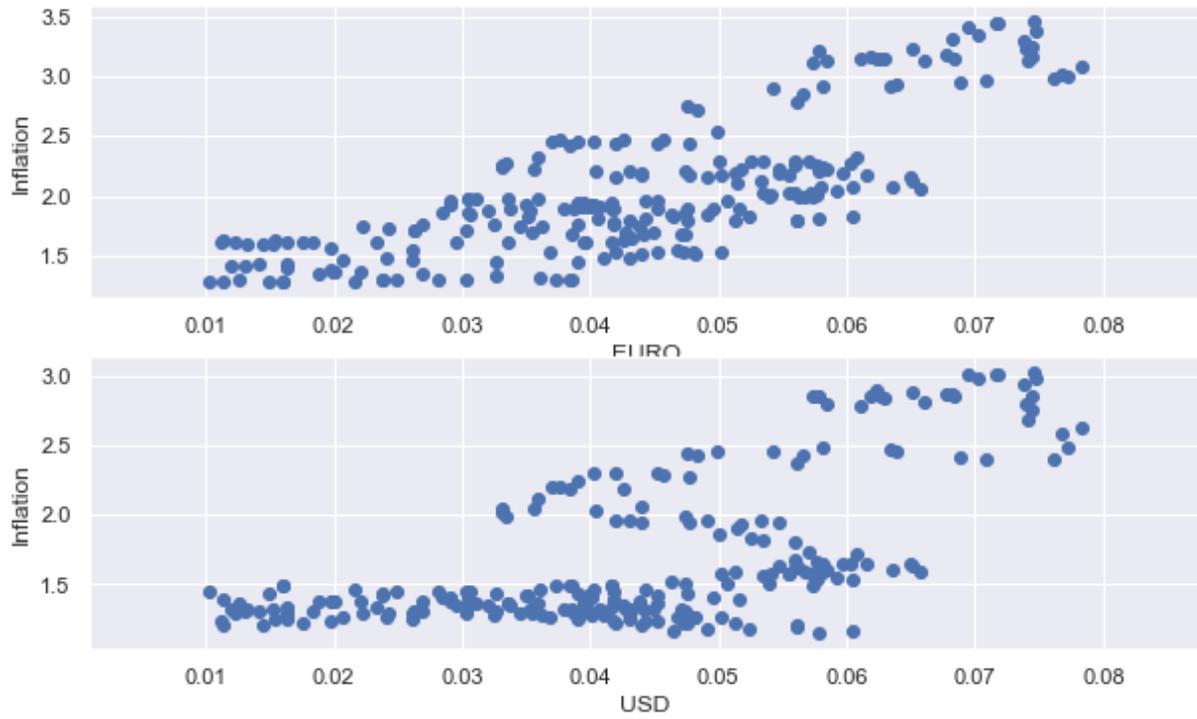


Figure 13. Nuage des points relatives à l'inflation et ses différents déterminants

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Ceci est confirmé, nous calculons la matrice de corrélation entre les variables.

Les valeurs de corrélations relativement fortes sont mises en évidence en vert(positif) ou en marron (négatif).

Les corrélations montrent que variables s'avèrent être d'importants prédicteurs de l'inflation.

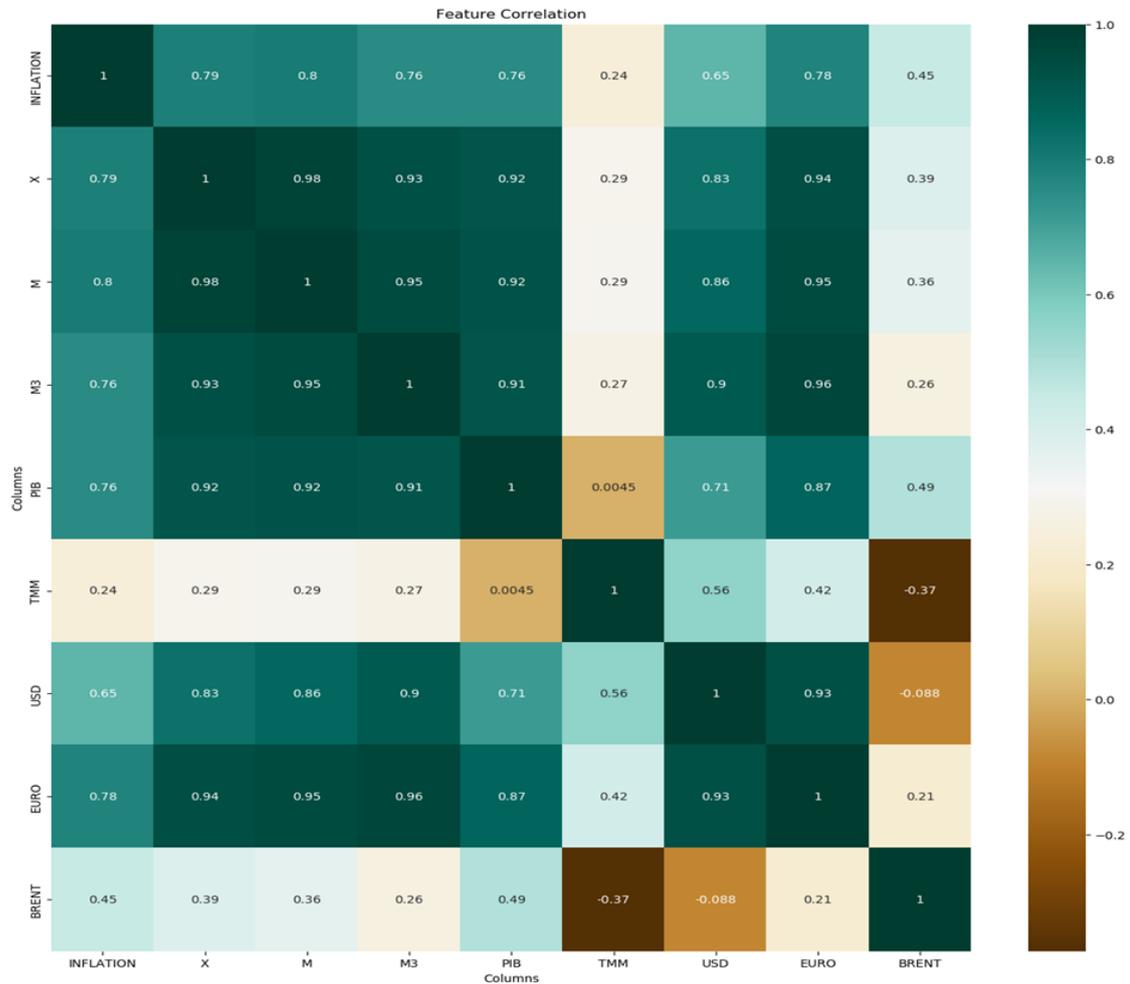


Figure 14. Matrice de corrélation.

3. Méthodologies & résultats

Dans cette section, les résultats de l'analyse de la performance relative hors échantillon des modèles de ML proposé pour la prévision de l'inflation sont présentés pour les comparer au benchmark.

Nous utilisons un cadre simple pour la prévision de l'inflation sur un horizon à court terme. Cet exemple s'explique par le fait qu'il s'agit également de l'horizon sur lequel on pense généralement que la politique monétaire doit se concentrer.

Nous verrons également que les techniques d'apprentissage automatique peuvent être appliquées à un "monde de petites données" traditionnel.

3.1 Les modèles économétriques (benchmark)

Une collection de benchmark, diversifiée et fondamentalement justifiable est cruciale pour l'évaluation de la performance des modèles de prévision.

En effet, la préoccupation principale est d'établir si le modèle développé est capable de réduire les erreurs de prévision rencontrées dans les modèles communément appliqués par les praticiens et les universitaires.

3.1.1 Prévision selon le modèle SARIMA

Nous avons construit notre modèle en déterminant tout d'abord l'ordre d'intégration de de l'inflation ainsi que la stationnarité comme indiqué dans la section précédente.

Compte tenu de la nature non stationnaire de la série, nous avons transformé les données afin de les rendre stationnaires. Nous avons également pris les différences secondes de la série afin de comparer les résultats avec ceux de la différence première.

En comparant la première et la deuxième différence, nous avons observé qu'il était préférable d'utiliser le logarithme de la première différence de la série afin de construire un bon modèle.

En d'autres termes, notre série était intégrée du premier ordre.

Dep. Variable:	Target	No. Observations:	223
Model:	SARIMAX(2, 1, 1)x(4, 0, 3, 12)	Log Likelihood	1000.988
Date:	Tue, 18 May 2021	AIC	-1979.977
Time:	03:42:15	BIC	-1942.547
Sample:	01-31-2001	HQIC	-1964.865
	- 07-31-2019		
Covariance Type:	opg		

Figure 15.La sélection du modèle SARIMA

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

La sélection du modèle SARIMA est basée sur le critère de Schwarz pour déterminer le nombre de termes ARMA.

La détermination du nombre de termes ARMA se fait en spécifiant un nombre maximum de coefficients AR ou MA, puis en estimant chaque modèle jusqu'à ces maxima, et nous évaluons chaque modèle en utilisant son critère d'information.

La meilleure spécification selon les critères d'information (AIC & BIC) est un SARIMA $(2,1,1) \times (4,0,1)_{12}$ et le modèle s'écrit selon l'équation :

$$\Phi(L^{12})\nabla_{12}^d Inflation_t = \Theta(L^{12}) \varepsilon_t$$

La prévision pour un horizon de 12 mois de l'inflation est présentée par le Graphique ci-dessous

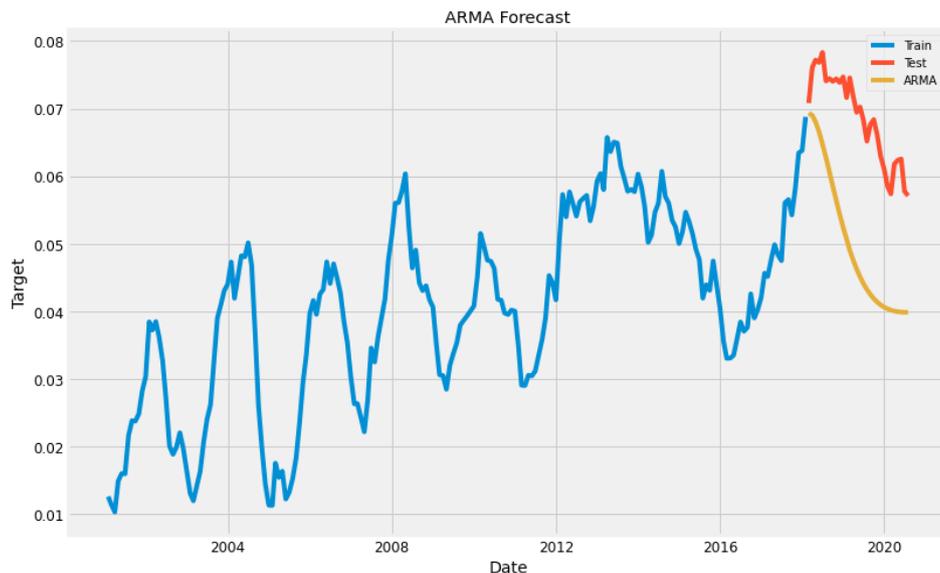


Figure 16. Prévision *out of sample* du modèle SARIMA

Le modèle SARIMA sélectionné peut être utilisé pour prévoir les valeurs futures car sa précision de prévision est acceptable pour un horizon de court terme.

Toutefois, le modèle SARIMA affiche une faible performance pour un horizon éloigné.

Pour la Tunisie, la faible performance du modèle SARIMA n'est pas une surprise étant donné que pour prévoir l'inflation ou doit tenir compte des interdépendances que l'inflation entretient avec un paquet de variables macroéconomiques qui sont particulièrement importantes pour la dynamique de l'inflation dans les économies de marché émergentes.

3.1.2 Prévision par VAR

Pour élaborer une autre prévision de l'inflation, nous adoptons la démarche multivariée centrée autour des modèles VAR.

On s'est basé sur la littérature pour déterminer les variables du modèle : l'inflation, le PIB, le taux d'intérêt, le cours de l'Euro, le cours du Dollar Américain, le cours du pétrole BRENT, l'agrégat monétaire M3, les importations et les exportations.

Le modèle VAR mis en œuvre reproduit l'approche de Cologni et Manera (2008).

Une distinction est que les auteurs utilisent des données trimestrielles, alors que le présent travail utilise des séries chronologiques mensuelles.

Par conséquent, il a été nécessaire de remplacer le PIB utilisé par les auteurs par une variable mensuelle corrélée ou une estimation mensuelle du PIB.

Afin de déterminer le nombre de retards selon le critère d'information d'Akaike (**AIC**) et le critère d'information bayésien (**BIC**), plusieurs combinaisons ont été testées jusqu'à ce que celle présentant la meilleure qualité, mesurée en termes de performance hors échantillon, a été obtenue. Le **nombre de retards** sélectionné est 4.

Le modèle VAR (4) est défini comme suit :

$$Y_t = C + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-4} + U_t \quad \text{avec } t = 0,1,2 \dots \quad , \quad E(U_t U_t') = \Omega$$

, et A_p contiennent les coefficients du modèle.

Où Y_t constitue un vecteur de variables endogènes au moment t :

$$Y_t = \begin{pmatrix} \text{Taux d'inflation} \\ TMM \\ M3 \\ Importation \\ Exportation \\ PIB \\ BRENT \\ EUR/TND \\ USD/TND \end{pmatrix}$$

D'après le test de co-intégration effectué (test de la trace), il existe, dans ce modèle, 2 relations de co-intégration entre les variables (l'hypothèse nulle d'absence de cointégration a été rejetée au seuil de 5%).

**PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR
DES DONNEES TUNISIENNES**

Tableau 5. Test de cointégration

Hypothesize d No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob
At most 1 *	0.219104	103.3324	95.75366	0.0136
At most 2	0.133436	59.31064	69.81889	0.2571
At most 3	0.086068	33.81768	47.85613	0.5118
At most 4	0.061029	17.79793	29.79707	0.5810
At most 5	0.035751	6.589165	15.49471	0.6258
At most 6	0.000612	0.109000	3.841466	0.7413
Trace test indicates 2 cointegrating eqn(s) at the 0.05 level				
* denotes rejection of the hypothesis at the 0.05 level				
**MacKinnon-Haug-Michelis (1999) p-values				

Selon le test Augmented Dicky Fuller, on peut constater que les résidus sont stationnaires. Cette condition vérifiée garantit la stationnarité des relations de cointégration.

Tableau 6. Test sur la stationnarité des résidus

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.337635	0.0146
Test critical values: 1% level	-3.466377	
5% level	-2.877274	
10% level	-2.575236	

Nous effectuons le test de la causalité au sens de Granger pour vérifier si les variables sont liées dans le temps, et nous concluons que plusieurs relations de causalité existent au sein du modèle. Une fois les conditions de validation du modèle vérifiées, nous pouvons passer à l'étape de la prévision.

Disposant d'un modèle valide, nous pouvons passer à la prévision de l'inflation à travers la spécification autorégressive. Pour cela, nous avons choisi de réaliser nos prévisions afin de pouvoir juger du pouvoir prédictif du modèle en les comparant aux réalisations observées, les résultats obtenus sont les suivants :

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

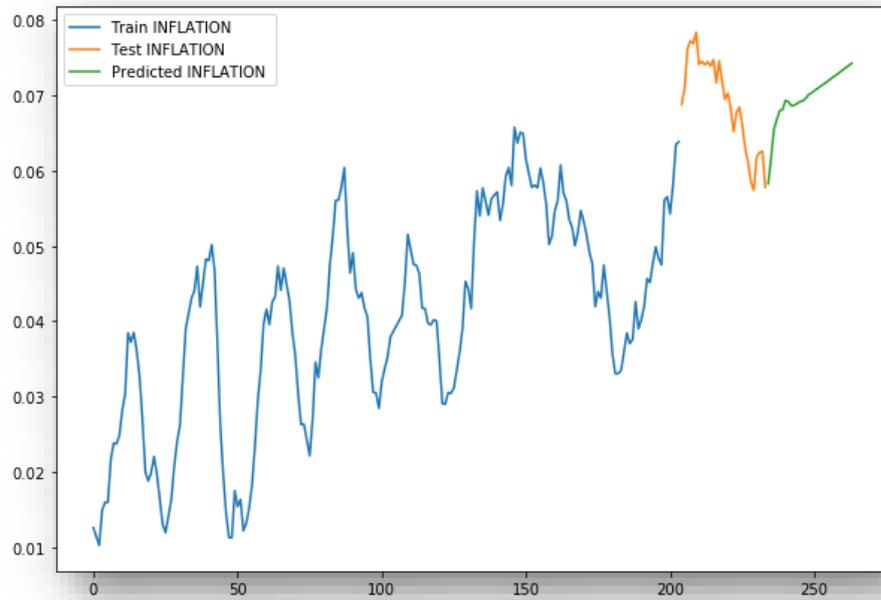


Figure 17. Prédiction out of sample du modèle VAR

Compte tenu de sa spécificité athéorique et le fait qu'elle soit basée sur l'extrapolation vectorielle, le modèle VAR s'appuie sur la dynamique des variables à travers le temps pour constituer leurs prévisions ce qui leur permet de capter toute l'information contenue dans les données et leurs évolutions sans que celle-ci ne soit identifiée.

Ainsi, ces caractéristiques précédemment citées font que les modélisations par VAR offrent une crédibilité aux prévisions vu leur capacité d'adaptation aux chocs subits par l'environnement socio- économique.

Cependant, la modélisation par le VAR présente néanmoins quelques inconvénients comme le fait que le modèle ne capte pas la non-linéarité dans la dynamique des variables macroéconomiques.

3.2 Les modèles de Machine Learning

3.2.1 Méthodologie de l'implémentation du modèle Long Short Term Memory et résultats

Les étapes habituelles suivies pour l'implémentation du modèle de réseau de neurone de type LSMT sont les suivantes :

Étape 1 : Identification des facteurs critiques influençant l'inflation en Tunisie et préparation des données :

- les variables déterminantes de l'inflation vont servir comme Input pour le réseau de neurone de type LSTM.

- le prétraitement des données concerne :

* la division de la base de données en trois sous-bases : base d'apprentissage, validation et test.

* La normalisation des données : la une remise à l'échelle des données (entre 0 et 1) : à l'aide de la fonction `MinMaxScale()`.

Étape 2 : La conception du modèle séquentiel LSTM et la sélection des paramètres d'apprentissage adéquats :

-Définition du réseau : Les réseaux neuronaux sont définis dans *Keras* comme une séquence de couches.

On crée les couches du réseau et on les ajoute dans l'ordre où elles doivent être connectées.

La couche récurrente LSTM composée d'unités de mémoire est appelée **LSTM ()**.

Une couche entièrement connectée qui suit souvent les couches LSTM et qui est utilisée pour produire une prédiction est appelée **Dense ()**.

La première couche du réseau doit définir **le nombre d'entrées** : Les entrées doivent être tridimensionnelles, composées d'échantillons, de pas de temps et de variables :

- **Échantillons.** Ce sont les lignes de la base de données.
- **Pas de temps.** Ce sont les observations passées pour une variable, comme les variables de retard.
- **Variables.** Ce sont les colonnes de la base de données.

-La compilation du réseau : Une fois que nous avons défini notre réseau, nous devons le compiler : La compilation requiert la spécification d'un certain nombre de **paramètres**, spécifiquement adaptés à la formation du réseau, à savoir : l'algorithme d'optimisation à utiliser pour former le réseau et la fonction de perte utilisée pour évaluer le réseau qui est minimisée par l'algorithme d'optimisation.

Étape 3 : Ajustement du modèle : Une fois le réseau compilé, il peut être ajusté, ce qui signifie de tester l'efficacité des paramètres sur un ensemble de données d'apprentissage.

Étape 4 : Prévision et évaluation de la performance hors échantillon du modèle proposé pour prévoir l'inflation.

Le raisonnement qui sous-tend le choix de ces paramètres particuliers est examiné en détail dans cette section :

Base d'apprentissage, de validation et de test :

Le défi central de l'apprentissage automatique est que les modèles doivent être raisonnablement performants sur de nouvelles bases de données préalablement définies.

Dans ce scénario, une solution populaire consiste à diviser les données d'entrée en échantillons de **d'apprentissage et de test**. Il est également habituel de séparer les données pour la **validation** pendant l'étape de d'apprentissage.

Lorsqu'on traite des séries temporelles, le processus de fractionnement précédent doit être adapté.

En effet, des divisions aléatoires vont certainement perturber l'autocorrélation de la série, ce qui les rend impropres à l'ajustement de tout modèle. Une alternative est d'implémenter cette procédure en blocs ou, de manière équivalente, d'inclure les retards de la série temporelle comme nouvelles variables.

De cette façon, une division ne masquera pas les autocorrélations, car chaque observation d'une variable donnée à un instant donné sera accompagnée des observations respectives de cette même variable, mais décalées dans le temps.

Outre le processus de fractionnement détaillé, des stratégies visant à améliorer la fiabilité de l'analyse des performances hors échantillon ont été élaborées.

L'une des approches privilégiées est k-Fold Cross-Validation, comme indiqué dans la section 3.

La valeur de k doit être choisie avec soin, car elle implique un compromis biais-variance qui peut compromettre l'évaluation de la compétence du modèle. Le compromis est associé au choix de k dans la validation croisée à k plis.

En règle générale, compte tenu de ces considérations, on effectue une k-fold validation croisée en utilisant **k = 5** ou **k = 10**, car ces valeurs ont été montrées empiriquement pour produire des estimations du taux d'erreur de test qui ne souffrent ni d'un biais excessivement élevé ni d'une variance très élevée.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Il convient de noter que, plus k est grand, plus la différence de taille entre l'ensemble d'apprentissage et le sous-échantillon de rééchantillonnage ne se réduit, plus le biais de la technique devient plus faible.

Pour cette étude, $k = 10$ a été adopté. En outre, la simulation de Monte Carlo a complété la validation croisée afin d'améliorer la fiabilité de l'analyse empirique.

Plus précisément, la division de l'ensemble de données en ensembles d'apprentissage, de validation et de test a été répétée plusieurs fois, donnant lieu à différents fractionnements.

Formation et optimisation des hyperparamètres de l'algorithme LSTM :

Pour l'implémentation du modèle LSTM, il est essentiel de choisir la fonction de perte et de l'algorithme d'optimisation convenables pour obtenir des performances prédictives concluantes. De nombreuses options admissibles sont disponibles dans la littérature, et une revue exhaustive n'entre pas dans le cadre de ce travail.

Néanmoins, en raison de l'importance des performances hors échantillon, un examen, même concis, est nécessaire pour justifier la conception du modèle proposé pour la prévision de l'inflation.

▪ **Le choix de la fonction de perte :**

Les fonctions de perte, la plus fréquente dans la littérature est **l'erreur quadratique moyenne (MSE)**.

Cette préférence s'explique par le fait que, dans de nombreux problèmes de régression, on obtient des résultats satisfaisants.

En outre, cette fonction est également utilisée pour l'ajustement de nombreux modèles de séries temporelles, ce qui facilite la comparaison entre l'apprentissage automatique et les modèles économétriques traditionnels.

▪ **La sélection de l'algorithme d'optimisations :**

En ce qui concerne la sélection de l'algorithme d'optimisation pour l'apprentissage, il n'y a pas de consensus dans la littérature.

Cependant, une approche récente et prometteuse a été avancée par Kingma et Ba (2015), appelée **ADAM** ("Adaptive Moment estimation"), qui est un algorithme d'optimisation de fonctions objectives stochastiques basée sur le gradient du premier ordre. ADAM se comporte bien pour les fonctions objectives non convexes, qui sont omniprésentes dans l'apprentissage automatique en obtenant de faibles erreurs quadratiques moyennes en un temps de calcul décent.

ADAM, associé à une fonction de perte quadratique et le *momentum de Nesterov* a affiché des résultats satisfaisants dans plusieurs applications et a également généré la meilleure performance hors échantillon dans le contexte de la prévision de l'inflation, ce qui justifie leur sélection lors de l'adaptation des modèles de réseaux de neurones considérés ici.

Le *momentum de Nesterov* accélère la convergence des algorithmes basés sur le gradient, ce qui explique son inclusion.

▪ **Le nombre d'époques¹¹ et la taille de lot pour l'algorithme LSTM :**

Enfin, il convient de discuter de l'influence du nombre d'époques et de la taille du lot dans le processus d'optimisation de l'algorithme LSTM.

Par définition, chaque époque correspond à un passage complet dans l'ensemble de données d'apprentissage, à la différence de la taille du lot, qui détermine le nombre d'échantillons traités avant la mise à jour des paramètres du modèle via l'algorithme d'apprentissage (optimisation).

Malheureusement, il n'existe pas de consensus dans la littérature concernant les valeurs adéquates de ces hyperparamètres. Ils doivent être calibrés de manière ad hoc, en choisissant généralement comme critère la performance hors échantillon, c'est-à-dire le pouvoir de généralisation du réseau.

Naturellement, il existe un compromis entre les performances dans l'échantillon et hors échantillon lors de la définition du nombre d'époques.

Plus le nombre d'époques augmente, plus le réseau passera par l'ensemble de données d'apprentissage, ce qui lui donne plus de chances d'apprendre les caractéristiques des entrées et d'améliorer ainsi la prédiction.

Cependant, dans le même temps, la probabilité d'un ajustement excessif augmente également, car le réseau peut apprendre comment reproduire avec précision l'ensemble de données d'apprentissage et, dans le processus, il peut perdre son pouvoir de généralisation parce que ses coefficients ont été réglés de façon excessive pour minimiser la fonction de perte dans l'ensemble de données d'apprentissage.

¹¹ Un Epoch décrit le nombre de fois où l'algorithme voit le jeu de données entier. Ainsi, chaque fois que l'algorithme a vu tous les échantillons du jeu de données, une époque est terminée.

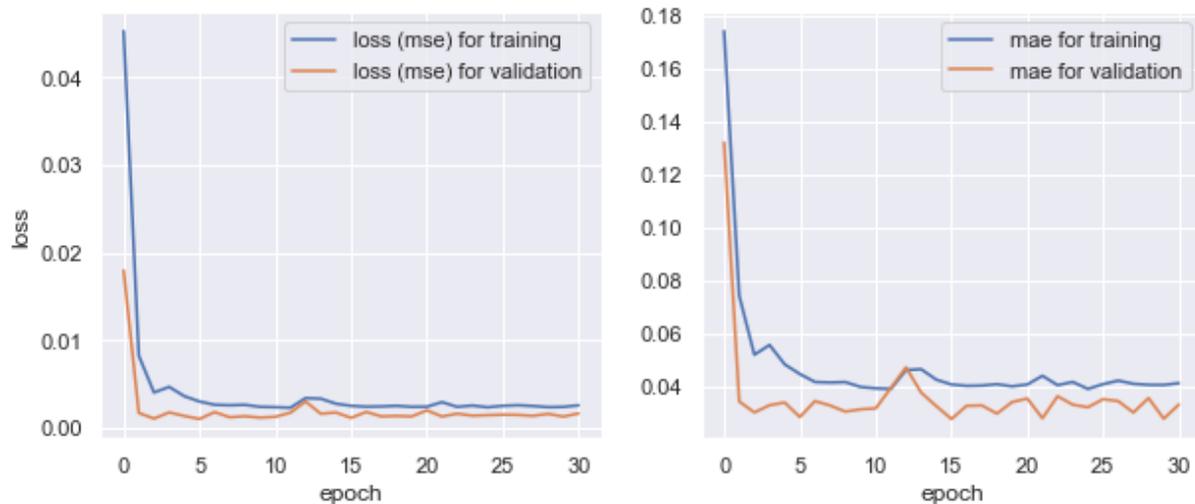


Figure 18. Illustration du comportement de MSE & MAE du modèle LSTM proposé dans ce travail pour la prévision de l'inflation en Tunisie

Par conséquent, la fonction de perte hors échantillon commence à diminuer avec l'augmentation du nombre d'époques (région de sous-adaptation) et atteint un minimum à un certain point et, par la suite, elle commence à augmenter en raison du surajustement.

Selon la figure 18, nous pouvons constater que le modèle a convergé assez rapidement et que les performances d'apprentissage et de validation sont restées équivalentes.

Pour cette raison, un nombre total de 30 époques a semblé raisonnable pour trouver le minimum de la fonction de perte hors échantillon, et sélectionner les paramètres correspondants.

Les effets de la taille du lot sur le processus d'apprentissage sont plus complexes et techniques. Dans la pratique, pour les réseaux profonds, il a été observé que les lots de grande taille conduisent à une dégradation importante de la qualité du modèle, mesurée par son pouvoir de généralisation.

Dans les simulations effectuées dans le cadre de ce travail, la taille des lots a été fixée par défaut à 32, fréquemment considérée dans la pratique pour équilibrer le compromis entre convergence et pouvoir de généralisation.

Language de programmation & bibliothèques utilisés :

Les modèles de ML utilisés dans ce travail ont été mis en œuvre principalement à l'aide de Python (version 3.9.7).

Les algorithmes ont été exécutés dans un PC avec un Intel Core i5-8250U fonctionnant sous Microsoft Windows avec 16 Go de RAM.

Pour les modèles d'apprentissage automatique, Tensorflow (version 2.3.0), Keras (version 2.4.3), et Scikit-Learn (version 0.23.2), également connu sous le nom de SKLearn, ont été utilisés.

Résultats obtenus par le modèle LSTM

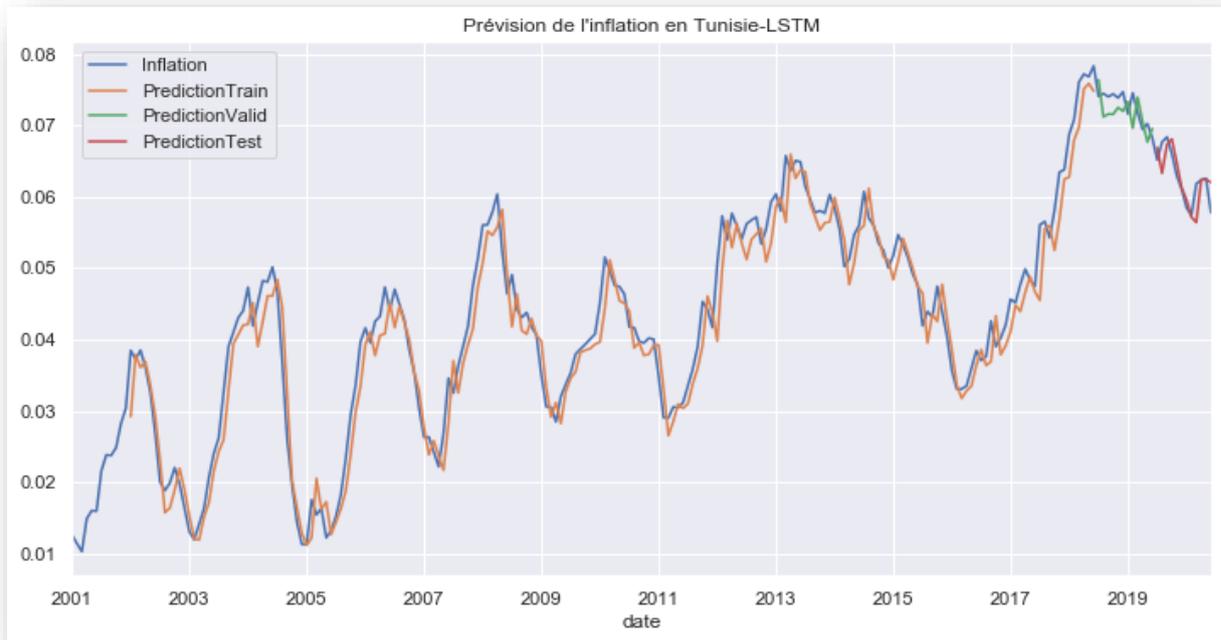


Figure 19. Prédiction *out of sample* par le modèle LSTM

Les résultats fournis par le modèle LSTM montre une performance prédictive acceptable pour la base d'apprentissage, la base de validation et la base test et ceci pour un horizon de 12 mois :

Tableau 7. RMSE & MAE relatifs au modèle LSTM

	RMSE	MAE
Base d'apprentissage (train)	0,0035	0,0028
Base de validation	0,0026	0,0023
Base de test	0,0025	0,0018

3.2.2 Méthodologie de l'implémentation des autres modèles de ML

Pour l'implémentation de la régression k-NN, on doit saisir le nombre de voisins pris en compte lors de la prédiction de la variable dépendante, c'est-à-dire que k doit être prédéfini.

Une valeur faible rend le modèle plus réactif et peut améliorer la qualité de l'ajustement dans l'échantillon, mais peut également conduire à un surajustement.

D'autre part, une valeur élevée de k produit des prédictions lisses, mais ne parvient pas à capturer la dynamique des données.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Dans les simulations exécutées, $k = 25$ a donné des résultats décents en termes de précision hors échantillon.

Dans le cas des forêts aléatoires, les hyperparamètres ont été calibrés empiriquement.

Le nombre d'arbres dans la forêt a été fixé à 20, sans profondeur maximale.

Le nombre minimum d'échantillons requis pour diviser un nœud interne est de 4, et le critère d'apprentissage choisi pour mesurer la qualité d'une division est le MSE.

Le nombre minimum d'échantillons de formation requis dans chaque branche gauche et droite d'un point de scission a été fixé à 1.

3.2.3 Comparaison des performances des prévisions *out of sample* & conclusions

Tableau 8. Comparaison des performances prédictives des modèles de ML par rapport au benchmark selon les deux métriques RMSE & MAE

		3 mois		6 mois		12 mois	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
Les modèles d'apprentissage profond (<i>Deep Learning</i>)	LSTM	0.0011	0.0008	0.0014	0.001	0.0025	0.0018
	Random Forest	0.0045	0.0032	0.0058	0.0041	0.0065	0.0062
KNN et les modèles basés sur les arbres décisionnels	KNN	0.0048	0.0035	0.0086	0.0077	0.012	0.009
	VAR	0.0051	0.0047	0.0059	0.0048	0.0066	0.0064
Les modèles économétriques	SARIMA	0.0062	0.0058	0.0068	0,0065	0.0087	0.0073

En comparant les métriques de tous les modèles utilisés, on peut déduire que le modèle gagnant est le LSMT selon le tableau 8.

Ce résultat s'explique par le nombre important de simulations, avec la division rigoureuse de l'échantillon en fenêtres d'apprentissage, de validation et de test.

Néanmoins, étant donné que les propriétés sous-jacentes du modèle LSTM lui confèrent une plus grande flexibilité accrue pour capturer la dynamique de l'inflation ce qui permet d'avoir des résultats solides pour les horizons courts, il est raisonnable de prétendre qu'il devrait être performant pour les horizons longs également et qu'il donne des résultats plus solides par rapport aux autres modèles de ML et aux modèles économétriques SARIMA et VAR.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

En revanche, le modèle de forêts aléatoires est moins performant que le modèle LSTM dans certaines fenêtres de prévision mais donne des résultats acceptables. Par contre le modèle KNN semble être moins efficace que les modèles standards pour certains horizons de prévisions.

Les résultats fournis par le modèle VAR étaient proches de certains modèles de ML et les surperforment dans certains horizons.

Cependant, les modèles de référence sont assez lisses et ne reflètent pas beaucoup la dynamique du taux d'inflation. Contrairement aux modèles d'apprentissage automatique qui ont des prédictions beaucoup plus variables, qui, au moins visuellement, varient davantage avec les données.

Néanmoins, même pour la méthode LSTM, il y a des sous-périodes où la prédiction diverge de la réalité.

Par conséquent, bien que la prévision de l'inflation reste un problème macro-économétrique difficile, les résultats présentés ici démontrent qu'il est possible de générer des prédictions informatives.

Une question qui se pose immédiatement lors de l'ajustement des modèles aux séries temporelles est de savoir si la performance supérieure d'un certain modèle se vérifie exclusivement dans une fenêtre temporelle particulière ou fenêtre temporelle particulière, ou si elle dépend des cycles économiques ou d'autres variables exogènes.

L'approche établie dans ce travail, basée sur des divisions successives de l'ensemble de données, concevant une collection diversifiée d'échantillons d'apprentissage, de validation et de test avec lesquels les modèles sont ajustés, répond à cette question.

Ainsi, chaque modèle a été entraîné sur différents échantillons, couvrant des périodes de temps distinctes, et testé sur plusieurs paramètres également.

Il est important de souligner d'après les résultats obtenus que les techniques de ML, essentiellement les modèles de *Deep Learning* s'avèrent être essentielles pour la boîte à outil de prévision dans les banques centrales vu leur capacité prédictive. La performance de ces modèles s'améliora davantage avec l'augmentation des quantités de données à la disponibilité de la BCT.

Cependant, le décalage entre les valeurs de l'inflation prévues et la valeur observée peut être expliqué par plusieurs facteurs.

Essentiellement, le phénomène de l'économie informelle qui occupe une place conséquente dans l'économie en Tunisie et sur lequel nous n'avons pourtant que peu ou pas d'information. Ce fléau interfère considérablement dans l'économie formelle et s'immisce dans tous les domaines : l'agro-alimentaire, le commerce, les services etc.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Ceci perturbe la dynamique économique du pays et accentue les pressions inflationnistes à cause des bénéfices non déclarés, les coûts de revient très bas par rapport à ce qui se pratique dans l'économie formelle, les circuits de contrebande etc.

CONCLUSION GENERALE

Le présent travail est consacré à l'évaluation des approches innovantes pour la prévision de l'inflation, un problème redoutable et non résolu qui a mis au défi les universitaires et les décideurs de la politique monétaire dans les banques centrales au cours des dernières décennies. Pour la banque centrale, il est essentiel d'identifier des modèles polyvalents pour la prévision de l'inflation, car son mandat est de maintenir le taux d'inflation à un niveau acceptable.

Un domaine d'intérêt important pour la banque centrale serait l'utilisation d'outils d'apprentissage automatique émergents pour améliorer le processus de prévision en exploitant la capacité de ces techniques à fournir de bonnes performances prédictives par rapport aux modèles standards.

En faisant partie de la boîte à outil de prévision de l'inflation, ces techniques peuvent contribuer à améliorer les décisions qui en résultent, sur la base d'un retour d'information précis des valeurs prédites, à des fins de planification et de mesures d'intervention.

Dans notre étude, après l'introduction de l'état de l'art des méthodes de prévision de l'inflation et la théorie économique sous-jacente, nous avons présenté une panoplie les principes des algorithmes de ML comme alternative puissante dans la boîte à outil des prévisions au niveau des banques centrales.

Dans l'application empirique, l'algorithme de ML de type LSTM est proposé en raison du succès que ce modèle a démontré dans plusieurs applications pratiques impliquant l'analyse de séries temporelles, en se référant à la littérature.

Dans le but de corroborer la supériorité de ce modèle préconisée, une sélection de benchmark comprenant des modèles économétriques et d'apprentissage automatique populaires est ajustée aux données pour la prévision de l'inflation en Tunisie.

Une comparaison de performance hors échantillon est mise en œuvre pour déterminer le modèle gagnant. Comme prévu, les expériences démontrent que le réseau LSTM permet d'obtenir des résultats convaincants par rapport au benchmark selon les métriques RMSE et MAE dans trois horizons de prévision.

En outre, le recours à ces approches alternatives s'explique par leur capacité à relever les défis de la prévision de l'inflation qui émergent en raison des non-linéarités et de la non-stationnarité. Ces caractéristiques ne peuvent pas être saisies par les modèles économétriques.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Cependant la méthode de prévision conduite par les techniques de ML peut avoir certaines limites. Premièrement, ces approches sont de type « boîte noire ». Ainsi, il n'existe pas de forme explicite pour expliquer et analyser la relation entre les entrées et les sorties définies dans les algorithmes. Aussi aucune méthode de test statistique formelle ne peut être utilisée. Cela entraîne des difficultés dans l'interprétation des résultats.

Notamment, ces techniques peuvent être coûteuses en termes de temps d'apprentissage et d'optimisation en fonction de l'algorithme utilisé.

De plus, les modèles de type LSTM en particulier sont assez généraux mais peuvent présenter une variance élevée dans l'estimation. C'est-à-dire qu'ils peuvent être trop dépendants des échantillons particuliers observés.

La recherche dans ce sujet de prévision de l'inflation à l'aide des techniques de ML peut être étendue dans les différentes directions : concernant les données utilisées et l'approche des modèles appliqués pour les prévisions.

Parmi les approches proposées, la combinaison des techniques de ML avec des méthodes économétriques plus transparentes peut permettre une interprétation rigoureuse (Özgür, Ö., & Akkoç,2021).

Notamment, pour un travail futur, la collecte d'une diversité de variables (utilisés comme prédicteurs) non seulement à partir domaine économique, mais aussi à partir des données politiques, de l'actualité et d'autres domaines liés à l'économie. Ceci est basé sur le fait que les environnements externes au modèle affectent directement ou indirectement l'inflation en influençant les conditions de manière positive/négative.

Citons à titre d'exemple Beckers, B. (2017), qui évaluent le discours du média allemand comme données non structurées pour la prévision de l'inflation et l'inflation anticipée.

L'étude de la performance des techniques d'apprentissage automatique pour une prévision à long terme peut être explorée dans le cadre de travaux futurs sur l'économie tunisienne. Les résultats peuvent différer considérablement.

Il est suggéré également de relier les algorithmes de ML à des sources de données pertinentes afin qu'ils sélectionnent automatiquement les variables de données dans l'environnement du modèle pour les prévisions. Cela permettrait d'améliorer les performances des algorithmes en éliminant l'intervention humaine dans le téléchargement des variables de données, qui serait sujette à des erreurs. L'automatisation aiderait les modèles à faire des prévisions périodiques basées sur les données reçues des sources liées.

Partant de ce qui précède, étant donné que la prise de décision moderne est de plus en plus fondée sur des preuves et construite autour de données et que leurs quantités augmentent

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

rapidement, nous pensons qu'il existe un grand nombre d'applications possibles pour l'apprentissage automatique dans les banques centrales, les gouvernements, les bureaux de statistiques et autres institutions similaires.

À long terme, ces techniques pourraient changer la façon dont nous voyons, modélisons et décidons des problèmes socio-économiques.

BIBLIOGRAPHIE

Adriansson, N., & Mattsson, I. (2015). Forecasting GDP Growth, or How Can Random Forests Improve Predictions in Economics ?

Agrawal, A., Gans, J., & Goldfarb, A. (2019). The Impact of Machine Learning on Economics. In *The Economics of Artificial Intelligence* (Issue May). <https://doi.org/10.7208/chicago/9780226613475.003.0021>

Ahmed, N. K., Atiya, A. F., El Gayar, N., & El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5), 594–621. <https://doi.org/10.1080/07474938.2010.481556>

Alam, T. (2019). Forecasting exports and imports through artificial neural network and autoregressive integrated moving average. *Decision Science Letters*, 8(3), 249–260. <https://doi.org/10.5267/j.dsl.2019.2.001>

Aldama, P., & Ouvrard, J.-F. (2020). Variantes analytiques du modèle de prévision et simulation de la Banque de France pour la France (FR-BDF) (Basic Model Elasticities of the Macroeconomic

Alimi, K. (2020). Essais sur la politique monétaire en Tunisie dans un cadre d'Équilibre Général Dynamique Stochastique Kawther Alimi To cite this version : HAL Id: tel-03003305 Kawther ALIMI.

Alles, L., & Horton, D. (1999). An evaluation of alternative methods of forecasting Australian inflation. *Australian Economic Review*, 32(3), 237–248. <https://doi.org/10.1111/1467-8462.00111>

Almosova, A. (2019). Nonlinear Inflation Forecasting with Recurrent Neural Networks Latest version is available here. May, 1–45.

Alnaa, S. E., & Abdul-Mumuni, A. (2012). Predicting Inflation in Ghana: A Comparison of Cointegration and Arima Models. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2065602>

Athey, S. (2018). L'impact de l'apprentissage automatique sur l'économie. 1–31.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Autoregressive, V. (1994). VAR models of inflation (1). 1, 231–239.

Babii, A., Ghysels, E., & Striaukas, J. (2020). Machine learning time series regressions with an application to nowcasting. ArXiv. <https://doi.org/10.1080/07350015.2021.1899933>

Bachelor Thesis : Econometric & Operational Research Erasmus University Rotterdam
Erasmus School of Economics Forecasting Inflation in Morocco with Parsimonious Factor

Banque Centrale de Tunisie. (2014). Les mécanismes de transmission de la politique monétaire.

Banque Centrale de Tunisie. (2021). Périodique de conjoncture, Juillet.

Banque Centrale de Tunisie. (2020).Rapport annuel

Baldacci, Emanuele and Buono, Dario and Kapetanios, (2019). Big Data and Macroeconomic Nowcasting: From Data Access to Modelling. Eurostat Statistical Book, 1, 1–476.

Batarseh, F. A., Gopinath, M., Nalluru, G., & Beckman, J. (2019). Application of machine learning in forecasting international trade trends. ArXiv, October 2019.

Beckers, B. (2017). Reading Between the Lines: Using Media to Improve German Inflation Forecasts. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.2970466>

Belloni, A., Chernozhukov, V., & Hansen, C. (2014). High-dimensional methods and inference on structural and treatment effects. Journal of Economic Perspectives, 28(2), 29–50. <https://doi.org/10.1257/jep.28.2.29>

Benes, J., Hlédik, T., Vávra, D., & Vlcek, J. (2003). The Quarterly Projection Model and its Properties. The Czech National Bank's Forecasting and Policy Analysis System.

BIT. (2004). Manuel de l'indice des prix à la consommation: théorie et pratique.

Bolhuis, M. A., & Rayner, B. (2020). Deus ex Machina? A Framework for Macro Forecasting with Machine Learning. IMF Working Paper, 25. <https://www.imf.org/en/Publications/WP/Issues/2020/02/28/Deus-ex-Machina-A-Framework-for-Macro-Forecasting-with-Machine-Learning-49094>

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Buchanan, B., & Miller, T. (2017). Machine Learning for policymakers. June, 1–48. <https://www.belfercenter.org/sites/default/files/files/publication/MachineLearningforPolicymakers.pdf>

Bundesbank, D., Bundesbank, D., Universit, F., & European, V. (2009). Axel A Weber : The role of forecasting for central banks. March, 1–6.

Caglayan, M., & Kocaaslan, O. K. (2015). Effects of Inflation on Output Gap : A MRS-IV Approach. 7, 3–23.

Canova, F. (2002). G-7 inflation forecasts. ECB Working Paper Series, 151(151).

Centrale, B., Centrale, B., & Centrale, B. (2017). Mise en œuvre de la politique monétaire.

Cerulli, G. (2020). Improving econometric prediction by machine learning. Applied Economics Letters, 00(00), 1–7. <https://doi.org/10.1080/13504851.2020.1820939>

Chakraborty, C., & Joseph, A. (2017). Staff Working Paper No . 674 Machine learning at central banks Staff Working Paper No . 674 Machine learning at central banks. 674.

Charpentier, A., Flachaire, E., & Ly, A. (2018). Econometrics and machine learning. *Economie et Statistique*, 2018(505–506), 147–169. <https://doi.org/10.24187/ecostat.2018.505d.1970>

Chen, J. M. (2020). Economic Forecasting With Autoregressive Methods and Neural Networks. SSRN Electronic Journal, 1–54. <https://doi.org/10.2139/ssrn.3521532>

Comparison of Alternative Inflation Forecasting Models in OPEC and BRICS countries
Olaoluwa Vincent AJAYI Thesis submitted for the degree of Doctor of Philosophy at the
Kingston University Department of Economics. (2019). February.

Coulombe, P. G., Leroux, M., Stevanovic, D., & Surprenant, S. (2020). How is machine learning useful for macroeconomic forecasting? ArXiv, August.

Cunha Medeiros, M., Vasconcelos, G., Veiga, A., & Zilberman, E. (2018). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.3155480>

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

- Delemarre, N., Letellier, M., & Lean, E. (2017). L ' Intelligence Artificielle.
- Doerr, S., & Gambacorta, L. (2021). Big data and machine learning in central banking. 930.
- End, N., El Hamiani Khatat, M., & Kolsi, R. (2020). Tunisia Monetary Policy Since the Arab Spring: The Fall of the Exchange Rate Anchor and Rise of Inflation Targeting. IMF Working Papers, 20(17). <https://doi.org/10.5089/9781513555027.001>
- Feki, R., & Bazin, D. (2012). La prévision de l ' inflation par la méthode des réseaux de neurones : Le cas de la Tunisie . 9(1).
- Final, A. (2014). Les mécanismes de transmission de la politique monétaire en. 1.
- Fisher Committee on Central Bank Statistics, I. (2018). IFC Bulletin 50 - The use of big data analytics and artificial intelligence in central banking (Issue 50). www.bis.org
- Fracasso, A., Genberg, H., & Wyplosz, C. (2003). How do central banks write? An evaluation of Inflation Reports by inflation-targeting central banks, Geneva Reports on the World Economy Special Report.
- Gillman, M. (2009). Inflation theory in economics: Welfare, velocity, growth and business cycles. *Inflation Theory in Economics: Welfare, Velocity, Growth and Business Cycles*, 1–401. <https://doi.org/10.4324/9780203880180>
- Gogas, P., Papadimitriou, T., Matthaiou, M., & Chrysanthidou, E. (2015). Yield Curve and Recession Forecasting in a Machine Learning Framework. *Computational Economics*, 45(4), 635–645. <https://doi.org/10.1007/s10614-014-9432-0>
- Hopp, D. (2021). Economic Nowcasting with Long Short-Term Memory Artificial Neural Networks (LSTM). 62.
- Hoxha, F. (2019). Forecasting Inflation Using Many Predictors. 423293.
- Jordan, T. J., De, C., & De, D. (2002). Prévisions d ' inflation par des modèles vectoriels autorégressifs. 40–66.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Joseph, A., Kalamara, E., Kapetanios, G., Potjagailo, G., Joseph, A., Kalamara, E., Kapetanios, G., & Potjagailo, G. (2021). Staff Working Paper No . 915 Forecasting UK inflation bottom-up Staff Working Paper No . 915 Forecasting UK inflation bottom up. 915.

Jung, J.-K., Patnam, M., & Ter-Martirosyan, A. (2018). An Algorithmic Crystal Ball: Forecasts based on Machine Learning. *IMF Working Papers*, 18(230), 1. <https://doi.org/10.5089/9781484380635.001>

Kierzenkowski, R. (2001). Le canal étroit du crédit : une analyse critique des fondements théoriques. 33.

KLOUDOVA, D. (2015). Estimating Output Gap and Potential Output for Russia and Its Usefulness by Forecasting Inflation. *International Journal of Economic Sciences*, IV(1), 45–59. <https://doi.org/10.20472/es.2015.4.1.003>

Kobbi, I., & Gabsi, F. B. (2017). The nonlinearity of the new Keynesian Phillips curve: The case of Tunisia. *Economies*, 5(3). <https://doi.org/10.3390/economies5030024>

Koenecke, A. (n.d.). Applying Deep Neural Networks to Financial Time Series Forecasting. 1–22.

Koop, G., & Onorante, L. (2019). Macroeconomic Nowcasting Using Google Probabilities. August, 17–40. <https://doi.org/10.1108/s0731-90532019000040a003>

Lack, C. (2006). *Swiss National Bank Economic Studies*. Swiss National Bank Economic Studies, 2, 24.

Landry, B. J., Bodi, N., & Ghislain, F. (2018). Prévisions de l' inflation et de la croissance en zone CEMAC Inflation and real growth forecasts in CEMAC zone Sommaire. 1–36.

Lassoued, A. (2006). Quel (s) indicateur (s) d ' inflation sous- jacente pour la Tunisie.

Lajmi, M., & KHADHRAOUI, S. EL. (2013). Modèle de Prévision à Moyen Terme pour la Tunisie. 2, 1–32. <http://www.bct.gov.tn/bct/siteprod/documents/modele.pdf>

Les, I., & Les, I. (n.d.). Les Mécanismes de l' Inflation. 1–6.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Liao, Y. (2017). Machine Learning in Macro-Economic Series Forecasting. *International Journal of Economics and Finance*, 9(12), 71. <https://doi.org/10.5539/ijef.v9n12p71>

Maehashi, K., & Shintani, M. (2020). Macroeconomic Forecasting Using Factor Models and Machine Learning: An Application to Japan. *Journal of the Japanese and International Economies*, 58(August), 101104.

Mahajan, K., & Srinivasan, A. (n.d.). Inflation Forecasting in Emerging Markets: A Machine Learning Approach Kriti Mahajan & Anand Srinivasan*. 1–45.

Martin, L.-C. (2019). Machine Learning vs Traditional Forecasting Methods: An Application to South African GDP. www.ekon.sun.ac.za/wpapers

Masini, R. P., Medeiros, M. C., & Mendes, E. F. (2020). Machine learning advances for time series forecasting. *ArXiv*, 679.

Medeiros, M. C., Vasconcelos, G. F. R., Veiga, Á., & Zilberman, E. (2021). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business and Economic Statistics*, 39(1), 98–119. <https://doi.org/10.1080/07350015.2019.1637745>

Mhamdi, G., Smida, M., & Farhani, R. (2015). Indicators of core inflation : Case of Tunisia
To cite this version : HAL Id : halshs-01138432.

Mifdal, R. (2019). Application des techniques d ' apprentissage automatique pour la prédiction de la tendance des titres financiers par.

Moshiri, S., & Cameron, N. (2000). Neural network versus econometric models in forecasting inflation. *Journal of Forecasting*, 19(3), 201–217.

Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87–106. <https://doi.org/10.1257/jep.31.2.87>

Mustapha, D. (2021). the Monetary Policy Instruments and Inflation, Analysis With a Monetary Policy Instruments and Inflation, Analysis With a Structural Break : an Application To Algeria. April.

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Mwangi, C. N. . (2016). An artificial neural network model for inflation forecasting in Kenya. Strathmore University, 11071(4828).

Nelson-douglas, B. (2004). Inflation Targeting Framework for Jamaica : an Empirical Exploration : Policy, 1–52.

Öğünç, F., Akdoğan, K., Başer, S., Chadwick, M. G., Ertuğ, D., Hülagü, T., Kösem, S., Özmen, M. U., & Tekatli, N. (2013). Short-term inflation forecasting models for Turkey and a forecast combination analysis. *Economic Modelling*, 33(February), 312–325. <https://doi.org/10.1016/j.econmod.2013.04.001>

Onder, E., Bayır, F., & Hepsen, A. (2013). Forecasting Macroeconomic Variables Using Artificial Neural Network and Traditional Smoothing Techniques. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2264379>

Ortega, J.-P., & Bauwens, L. (2014). Mixed-frequency modeling and economic forecasting.

Ouerghi, A., Hasni, M., Jaidi, Z., & Layeb, S. B. (2019). A new combined linear-artificial neural network-based model for accurate inflation forecasting in Tunisia. *International Journal of Decision Sciences, Risk and Management*, 8(4), 220. <https://doi.org/10.1504/ijdsrm.2019.106907>

Özgür, Ö., & Akkoç, U. (2021). Inflation forecasting in an emerging economy: selecting variables with machine learning algorithms. *International Journal of Emerging Markets*, February. <https://doi.org/10.1108/IJOEM-05-2020-0577>

Paper, W. (2014). Thinking outside the container. 2004(04), 4–7.

Paranhos, L. (2021). Predicting Inflation with Neural Networks. November 2020. <http://arxiv.org/abs/2104.03757>

Pasaogullari, M., & Meyer, B. H. (2010). Simple Ways to Forecast Inflation: What Works Best? *Economic Commentary (Federal Reserve Bank of Cleveland)*, 1–6. <https://doi.org/10.26509/frbc-ec-201017>

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Patrick, C., & Akanbi, O. A. (2017). The Relative Importance of the Channels of Monetary Policy Transmission in a Developing Country: The Case of Zambia. *African Journal of Economic Review*, 5(2), 149–174. <https://doi.org/10.22004/ag.econ.264570>

Plag, L. (2019). Bachelor Thesis : BSc 2 Econometrics & Economics Predicting South African GDP Growth Rates Using Factor Models and Machine Learning Techniques.

Qureshi, S., & Demers, F. S. (2020). Forecasting Canadian GDP growth using XGBoost. *Forecasting Canadian GDP growth using XGBoost*. August.

Rajkumar, V. (2015). Predicting Surprises to GDP: A Comparison of Econometric and Machine Learning Techniques. *Proceedings - 2011 4th IEEE International Conference on Utility and Cloud Computing, UCC 2011*, 1, 1–172.

Richard, O. (n.d.). Forecasting Inflation Variables Using Artificial Neural Network Techniques. 1–56.

Richardson, P. (2018). L'apport des Big Data pour les prévisions macroéconomiques à court terme et « en temps réel » : une revue critique. 2015, 65–87.

Richardson, P. (2018). Nowcasting and the use of big data in short-term macroeconomic forecasting: A critical review. *Economie et Statistique*, 2018(505–506), 65–87. <https://doi.org/10.24187/ecostat.2018.505d.1966>

Robertson, J. C. (2000). Central Bank Forecasting: An International Comparison. *Economic Review, Federal Reserve Bank of Atlanta Q2*, 82, 21–32.

Schier, R., Jurowetzki, R., & Raza, H. (n.d.). Intelligent Machines in Economics. 1–38.

Šestanović, T. (2019). Jordan neural network for inflation forecasting. *Croatian Operational Research Review*, 10(1), 23–33. <https://doi.org/10.17535/crorr.2019.0003>

Shmueli, G. (2010). To explain or to predict? *Statistical Science*, 25(3), 289–310. <https://doi.org/10.1214/10-STS330>

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Skrove Falch, N., & Nymoen, R. (2011). The Accuracy of a Forecast Targeting Central Bank. *Economics: The Open-Access, Open-Assessment E-Journal*, 5(2011–15), 1. <https://doi.org/10.5018/economics-ejournal.ja.2011-15>

Smalter Hall, A., & Cook, T. R. (2017). Macroeconomic Indicator Forecasting with Deep Neural Networks. *SSRN Electronic Journal*, September. <https://doi.org/10.2139/ssrn.3046657>

Stevanovic, D. (2020). Préviation macroéconomique dans l'ère des données massives et de l'apprentissage automatique.

Stock, J. H., & Watson, M. W. (2017). Twenty years of time-series econometrics in ten pictures. *Journal of Economic Perspectives*, 31(2), 59–86. <https://doi.org/10.1257/jep.31.2.59>

The survey, B. I. G. D., & Forum, O. (n.d.). Big Data in Central Banks.

Szafranek, K. (2017). Bagged artificial neural networks in forecasting inflation: Bagged artificial neural networks in forecasting inflation. *Narodowy Bank Polski*, 262.

Szyszko, M. (2015). Inflation Forecasts Versus Shaping Inflation Expectations. *Comparative Analysis. Comparative Economic Research*, 18(4), 139–156. <https://doi.org/10.1515/cer-2015-0033>

Treichel, V. (1997). Broad Money Demand and Monetary Policy in Tunisia. In *IMF Working Papers* (Vol. 97, Issue 22, p. 1). <https://doi.org/10.5089/9781451921250.001>

Tura-gawron, K. (2016). Credibility of Central Banks Credibility of Central Banks. 2016(7). <https://doi.org/10.13140/RG.2.2.22144.23044>

Urrutia, J. D., Longhas, P. R. A., & Mingo, F. L. T. (2019). Forecasting the Gross Domestic Product of the Philippines using Bayesian artificial neural network and autoregressive integrated moving average. *AIP Conference Proceedings*, 2192. <https://doi.org/10.1063/1.5139182>

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Verstyuk, S. (2020). Modeling Multivariate Time Series in Economics: From Auto-Regressions to Recurrent Neural Networks. SSRN Electronic Journal, November 2018. <https://doi.org/10.2139/ssrn.3589337>

Viii-, B. O. X. (2005). Central Bank inflation forecasting methods. March 2001, 2001–2002.

Visscher, P. E. (2018). Artificial Neural Networks. Forecasting Time Series.

Wolozko, N. (2017). Economic Modelling & Machine Learning a Proof of Concept. Oecd.

Yassen, A. A. (2011). Comparative Study of Artificial Neural Network and ARIMA Models for Economic Forecasting. 22.

Zahara, S., Sugianto, & Ilmiddaviq, M. B. (2020). Consumer price index prediction using Long Short Term Memory (LSTM) based cloud computing. Journal of Physics: Conference Series, 1456(1). <https://doi.org/10.1088/1742-6596/1456/1/012022>

Zardi, S. C. (2017). Forecasting inflation in a macroeconomic framework: An application to Tunisia. 2, 1–24.

Zhang, L., & Li, J. (2012). Inflation forecasting using support vector regression. Proceedings of the 2012 4th International Symposium on Information Science and Engineering, ISISE 2012, 136–140. <https://doi.org/10.1109/ISISE.2012.37>

TABLE DES MATIÈRES

REMERCIEMENTS.....	3
LISTE DES ABREVIATIONS	4
LISTE DES FIGURES.....	6
LISTE DES TABLEAUX.....	7
INTRODUCTION GENERALE.....	10
CHAPITRE PREMIER : L'INFLATION & LA POLITIQUE MONETAIRE.....	13
Introduction	13
Section 1 : Vue générale sur l'inflation & les techniques de prévision	15
1. Définition de l'inflation.....	15
2. Types & mesures de l'inflation	15
3. Les mécanismes économiques de l'inflation.....	18
3.2 L'inflation par la monnaie :	19
3.3 L'inflation par les coûts :	19
3.4 L'inflation structurelle :	20
3.5 L'inflation liée aux anticipations des agents économiques :.....	21
4. Les déterminants de l'inflation.....	22
Section 2 : Les techniques de prévisions de l'inflation	24
1. Revue de la littérature académique relative aux outils de prévision de l'inflation	24
2. Dispositifs de prévision de l'inflation dans les banques centrales	26
2.1 Prévision de l'inflation par la BCT	28
2.2 Prévision de l'inflation dans la banque de Suisse	30
2.3 Prévision de l'inflation dans la Banque d'Angleterre Royaume-Uni.....	30
2.4 La prévision de l'inflation dans la Réserve fédérale américaine	31
3. Les méthodes conventionnelles : Revue de la littérature	32
3.1 Les modèles univariés ARIMA.....	33
3.2 Le modèle VAR et cointégration	35

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

Section 3 : La politique monétaire et le contrôle de l'inflation.....	39
1. Définition et objectifs de la politique monétaire	39
1.1 Définition générale.....	39
1.2 Les objectifs de la politique monétaire	40
2. Les instruments de la politique monétaire face à l'inflation	41
2.1 La politique de pilotage de taux d'intérêt	41
2.2 Le contrôle de concours à l'économie :	42
2.3 Les réserves obligatoires :.....	42
3. Les canaux de transmission de la politique monétaire	43
3.1 Le canal du taux d'intérêt	43
3.2 Le canal du crédit.....	44
3.3 Le canal du taux de change	44
3.4 Le canal des actifs financiers	45
3.5 Le canal des bilans bancaire.....	45
3.6 Le canal des anticipations	46
4. Le <i>reporting</i> des prévisions sur l'inflation & la transition au régime de ciblage d'inflation 47	
Conclusion.....	48
CHAPITRE 2 : LES TECHNIQUES DE MACHINE LEARNING : PRINCIPE & APPLICATION EMPIRIQUE SUR DES DONNEES TUNISIENNES	50
Introduction	50
Section 1 : Contextualisation et généralités sur l'intelligence artificielle	52
Section 2 : Exploration des techniques de Machine Learning	53
1. Définition de Machine Learning :	53
2. Les types d'apprentissage :	54
3. Les algorithmes de Machine Learning	55
3.1 K-Nearest Neighbors et les modèles basés sur les arbres décisionnelles	55
3.3 Les modèles d'apprentissage profond (<i>Deep Learning</i>).....	58
4. L'utilisation des techniques de Machine Learning dans la prévision de l'inflation.....	67
5. Le langage de programmation de Machine Learning & les bibliothèques clé.....	69
Section 3 : L'économétrie & les techniques de Machine Learning	72

PREVISION DE L'INFLATION : L'APPORT DU MACHINE LEARNING SUR DES DONNEES TUNISIENNES

1. L'économétrie Versus le Machine Learning.....	72
2. L'économétrie combinée avec les techniques de Machine Learning :.....	76
2.1 Les techniques de Machine Learning utilisées dans l'économétrie.....	77
2.2 Les techniques économétriques utilisées dans les modèles de Machine Learning.....	79
Section 4 : Une application sur des données tunisiennes	81
1. L'inflation en Tunisie : une analyse descriptive	81
1.1 La dynamique de l'inflation en Tunisie	81
1.2 L'évolution des déterminants de l'inflation	86
1.3 Les propriétés statistiques de la variable « inflation »	88
2. Les variables de la base de données	90
3. Méthodologies & résultats	95
3.1 Les modèles économétriques (benchmark).....	95
3.2 Les modèles de Machine Learning	100
CONCLUSION GENERALE	109
BIBLIOGRAPHIE	112
TABLE DES MATIÈRES	122