




INSTITUT INTERNATIONAL DE RECHERCHE
POUR LE DÉVELOPPEMENT DURABLE (IIRDD)

MODÉLISATION DE L'ÉVOLUTION DES ANOMALIES DE TEMPÉRATURE GLOBALE ET DES GAZ À EFFET DE SERRE (GES)

Analyse par modèles ARIMA et ARDL



Dr. Claude AHOANGNINO (PhD)
Maître de Recherche - IIRDD, Québec, Canada

Année académique : 2024-2025

Institut international de Recherche pour le Développement Durable (IIRDD)
Rapport de recherche en économétrie environnementale





INSTITUT INTERNATIONAL DE RECHERCHE
POUR LE DEVELOPPEMENT DURABLE

Rapport de recherche

Econométrie Environnementale

**Modélisation de l'évolution des anomalies de
température globale et des Gaz à effet de
serre à l'aide des modèles ARIMA et ARDL**

Réalisé par :

Dr. Claude AHOUANGNINOU (PhD)

Maître de Recherche, IIRDD, Québec, Canada

Année académique : 2024-2025

Index

A

ADF, 25, 34, 35, 36, 50, 72
apprentissage automatique, 23
AR (Auto-Regressive), 13
ARCH, 4, 5, 6, 9, 10, 15, 16, 17, 18, 19, 22, 23, 34, 37, 38, 39, 52, 56, 60, 63, 65, 70, 72
ARDL, 3, 4, 5, 6, 9, 10, 11, 25, 26, 33, 34, 35, 40, 41, 43, 44, 49, 50, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 88
ARIMA, 3, 4, 5, 6, 9, 10, 11, 13, 14, 15, 22, 23, 24, 33, 34, 35, 36, 37, 39, 41, 43, 44, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 72, 73, 74, 77, 78, 79, 83
ARIMA(p, d, q), 14
auto_ardl(), 41, 67

B

boosting, 24

C

changements climatiques, 6, 7, 8, 9, 19, 20, 31
climat, 3, 6, 7, 8, 9, 11, 12, 22, 23, 26, 28, 30, 31, 45, 73, 75, 82
Cointégration, 24, 69, 72

D

Dickey-Fuller augmenté, 35, 36, 50
dioxyde de carbone (CO₂), 3, 6, 26, 33, 44, 46
dplyr, 34

E

Engle et Granger, 25, 40
erreur aléatoire, 16
Extreme Value Theory - EVT, 23

F

FinTS, 34, 38, 52
forecast, 34, 36, 38
Forêts aléatoires (Random Forests), 24
Fréchet, 23, 40

G

GARCH, 4, 5, 6, 9, 10, 11, 17, 18, 19, 22, 23, 24, 38, 39, 44, 52, 56, 60, 63, 65, 71, 72, 73, 74, 75, 79
Gas à effet de serre (GES), 9
Generalized Pareto Distribution (GPD), 23
ggfortify, 35
ggplot2, 34

Gumbel, 23, 40

I

I (Integrated), 14

L

Les gaz à effet de serre (GES), 6
logiciel R, 34
Long Short-Term Memory, 24
lubridate, 34

M

MA (Moving Average), 14
machine learning, 23, 87
MAE, 37, 41, 42, 55, 58, 61, 64, 66
MAPE, 37, 41, 42, 55, 58, 61, 64, 66
MASE, 37, 41, 42, 66
méthane (CH₄), 3, 6, 26, 33, 44, 47, 68
modélisation, 6, 9, 10, 13, 16, 18, 22, 23, 35, 43, 44, 49, 50, 72, 75
moyenne conditionnelle, 16

N

NASA GISS, 4, 33
NOAA GML, 34

O

OLS, 25

P

protoxyde d'azote (N₂O), 3, 6, 26, 33, 44, 48, 73

R

readxl, 34
Réseaux de neurones artificiels, 24
Réseaux de neurones convolutifs, 24
Réseaux de neurones récurrents, 24
RMSE, 37, 41, 42, 55, 58, 61, 64, 66

S

SARIMA (Seasonal Autoregressive Integrated Moving Average), 14

T

Test de Johansen, 25
test de Ljung-Box, 37, 51, 56, 59, 62

Tests de stationnarité, 35

Theil's U, 37, 41, 42, 66

théorie des valeurs extrêmes (EVT), 9, 71, 73, 75

tidyr, 34

tidyverse, 34

tseries, 34, 35

U

urca, 34, 35

V

Value-at-Risk (VaR), 22, 38, 39, 71, 75

VAR (Vector AutoRegressive), 25

variance conditionnelle, 16, 18

W

Weibull, 23, 40

X

xts, 34

Z

zoo, 34

SARIMA(p, d, q)(P, D, Q, s), 15

Remerciements

J'adresse mes vifs remerciements à toute l'équipe de recherche de l'Institut International de Recherche pour le Développement Durable (IIRDD) ainsi qu'aux relecteurs du présent rapport. J'exprime également ma profonde gratitude au Professeur Yazid DISSOU, Professeur titulaire d'Économie à l'Université d'Ottawa au Canada, à Dr. Thibaud MARTIN, Directeur de Recherche au CIRAD/France, ainsi qu'à Dr. Ibrahim ELGHAZI, Chargé de Recherche Senior à l'IIRDD pour leur lecture attentive et leur évaluation constructive.

Résumé

Ce travail de recherche s'inscrit dans une perspective d'analyse quantitative du changement climatique, en étudiant la dynamique des anomalies de température globale et des gaz à effet de serre (GES), notamment le dioxyde de carbone (CO₂), le méthane (CH₄) et le protoxyde d'azote (N₂O). L'objectif principal est de modéliser ces séries temporelles à l'aide des modèles ARIMA et ARDL, et d'identifier d'éventuelles relations de long terme entre les émissions de GES et le réchauffement climatique.

L'étude repose sur des données climatiques annuelles issues de sources officielles (NOAA, NASA GISS), couvrant des périodes variables selon les séries. Les tests de stationnarité indiquent que les anomalies de température sont intégrées d'ordre 1, tandis que le CO₂, le CH₄ et le N₂O sont intégrés d'ordre 2. Des modèles ARIMA ont été estimés pour chaque série, avec des performances prédictives satisfaisantes. Les tests sur les résidus ont confirmé la validité des modèles (absence d'autocorrélation, pas de volatilité conditionnelle, normalité).

L'approche ARDL a permis d'étudier l'effet conjoint du CO₂ et du CH₄ sur les anomalies de température. Le modèle retenu, un ARDL(1,0,0), présente des coefficients significatifs pour le CH₄ ($p < 0,001$) et le CO₂ ($p < 0,01$), avec un R² ajusté de 0,845. Le test de cointégration de Pesaran confirme une relation de long terme ($F = 11,34$; $p < 0,001$). Les tests diagnostiques indiquent l'absence d'autocorrélation, d'hétéroscédasticité conditionnelle (ARCH) et une distribution normale des résidus. À l'inverse, les modèles de type GARCH, VaR ou EVT ont été écartés, les séries ne présentant pas de comportement instable ou extrême.

Ces résultats mettent en évidence le rôle structurant des concentrations de GES, en particulier du CO₂, dans l'évolution des anomalies de température. Ils soutiennent la nécessité de politiques climatiques ambitieuses et fondées sur des analyses empiriques solides. Ce travail ouvre la voie à des recherches futures mobilisant des données à fréquence plus élevée, des facteurs explicatifs supplémentaires, ou des approches multivariées dynamiques.

Mots-clés : changement climatique, anomalies de température, GES, ARIMA, ARDL, cointégration

Abstract

This research adopts a quantitative approach to climate change analysis, focusing on the dynamics of global temperature anomalies and greenhouse gases (GHGs), notably carbon dioxide (CO₂), methane (CH₄), and nitrous oxide (N₂O). The main objective is to model these time series using ARIMA and ARDL models, and to identify possible long-term relationships between GHG emissions and global warming.

The study is based on annual climate data from official sources (NOAA, NASA GISS), covering different periods depending on the variable. Stationarity tests indicate that temperature anomalies are integrated of order 1, while CO₂, CH₄, and N₂O are integrated of order 2. ARIMA models were estimated for each series, showing satisfactory predictive performance. Residual analysis confirmed the statistical validity of the models (no autocorrelation, no conditional heteroskedasticity, normally distributed residuals).

The ARDL approach was used to analyze the joint effect of CO₂ and CH₄ on temperature anomalies. The selected model, an ARDL(1,0,0), shows significant coefficients for CH₄ ($p < 0.001$) and CO₂ ($p < 0.01$), with an adjusted R² of 0.845. The Pesaran bounds test confirms the existence of a long-term relationship ($F = 11.34$; $p < 0.001$). Diagnostic tests indicate no residual autocorrelation, no ARCH effects, and normal residual distribution. Conversely, GARCH, VaR, and EVT models were excluded, as the series showed no unstable or extreme behavior.

These results highlight the structural role of GHG concentrations, particularly CO₂, in driving temperature anomalies. They support the implementation of ambitious climate policies grounded in robust statistical modeling. The study also opens perspectives for future research using higher-frequency data, additional explanatory variables, or multivariate dynamic models.

Keywords: climate change, temperature anomalies, GHG, ARIMA, ARDL, cointegration

Table des Matières

Table des matières

Index	2
Remerciements	4
Résumé	4
Abstract	5
Table des Matières	6
Liste des Tableaux	8
Liste des Figures	8
Introduction	10
Chapitre 1 : Problématique, Objectifs et Hypothèses	11
1.1. Problématique	11
1.2. Objectifs de la recherche	14
1.3. Hypothèses de recherche	15
2. Cadre conceptuel et revue de littérature	16
2.1. Clarification des concepts	16
2.1.1. Changement climatique	16
2.1.2. Variabilité climatique	16
2.1.3. Gaz à effet de serre	16
2.1.4. Température	17
2.1.5. Anomalies de température	17
2.1.6. Précipitations	17
2.1.7. Modélisation	18
2.2. Revue de littérature	24
2.2.1. Changements climatiques et Gas à effet de serre	24
2.2.2. Interaction entre composantes des écosystèmes et les GES	26
2.2.3. Modélisation statistique des séries temporelles climatiques	26
2.2.4. Volatilité dans les séries temporelles et analyse	27
2.2.5. Apprentissage automatique et modélisation du climat	28
2.2.6. Cointégration	29
2.2.7. Lien entre économie et changement climatique	31
3. Méthodologie	38
3.1. Description des données	38
3.2. Prétraitement des données	39
3.3. Tests de stationnarité	40

3.4. Modélisation ARIMA	40
3.4.1. Structure générale d'un modèle ARIMA	40
3.4.2. Procédure d'estimation	41
3.5. Tests sur les résidus	42
3.5.1. Test de Ljung-Box (autocorrélation résiduelle)	42
3.5.2. Test ARCH (volatilité conditionnelle)	42
3.5.3. Validation visuelle et statistique	43
3.6. Méthodes complémentaires : GARCH, VaR et Extreme Value Theory	43
3.6.1. Modèle GARCH	43
3.6.2. Value-at-Risk (VaR)	44
3.6.3. Extreme Value Theory (EVT)	44
3.7. Analyse de la cointégration	45
3.7.1. Justification de la cointégration	45
3.7.2. Test de cointégration par l'approche ARDL - Bounds Testing	45
3.7.3. Modèle ARDL	45
3.8. Validation des modèles et prévisions	46
3.9. Limites de l'étude	48
3.9.1. Limites liées aux données	48
3.9.2. Limites liées à la modélisation	48
Chapitre 4 : Résultats	49
4.1. Résultats d'analyse descriptive des séries	49
4.1.1. Évolution de la température globale	49
4.1.2. Tendances des concentrations de CO ₂	50
4.1.3. Tendances des concentrations de CH ₄	52
4.1.4. Tendances des concentrations de N ₂ O	53
4.1.5. Corrélations entre les séries	54
4.2. Résultats des tests de stationnarité	54
4.3. Résultats de l'estimation des modèles ARIMA	56
4.3.1. Température globale	56
4.3.2. CO ₂	60
4.3.3. CH ₄	63
4.3.4. N ₂ O	67
4.3.5. Évaluation des résidus	70
4.3.6. Performance de prévision	70
4.4. Résultats du modèle ARDL	71
4.4.1. Présentation du modèle estimé	72

4.4.2. Estimation des coefficients	72
4.4.3. Test de cointégration (Bounds F-test)	73
4.4.4. Interprétation des relations de long terme	74
4.4.5. Diagnostics du modèle	74
4.5. Non implémentation des modèles GARCH, VaR et EVT	76
Chapitre 5 : Discussion des résultats	77
5.1. Modélisation univariée : ARIMA	77
5.2. Cointégration et modélisation multivariée : ARDL	77
5.3. Limites de l'étude et perspectives	78
5.4. Perspectives régionales et application en Afrique	79
Chapitre 6 : Conclusion générale et suggestions	80
6.1. Conclusion générale	80
6.2. Suggestions	80
Bibliographie	82
Annexes	91

Liste des Tableaux

Tableau 1: Données utilisées.....	46
Tableau 2: Matrice de Corrélation	54
Tableau 3: Résultats du test ADF	55
Tableau 4: : Estimation du modèle ARIMA (1,1,3) des anomalies de températures	56
Tableau 5: : Résultats d'estimation du modèle ARIMA (2,2,3)	60
Tableau 6: : Résultats d'estimation du modèle ARIMA (2,2,0)	64
Tableau 7: : Résultats d'estimation du modèle ARIMA (0,2,1)	67
Tableau 8: : Performance de prévision des modèles sur le test.....	71
Tableau 9: Résultats du test de Breusch-Godfrey	74

Liste des Figures

Figure 1: : Evolution des anomalies de température annuelle globale	50
Figure 2: : Evolution annuelle des concentrations de CO2	51
Figure 3: : Evolution annuelle croisée des concentrations de CO2 et anomalie de température moyenne mondiale	52
Figure 4: : Evolution des concentrations de méthane (CH4).....	53
Figure 5: : Evolution des concentrations de protoxyde d'azote (N2O).....	54
Figure 6: : Résidus du modèle ARIMA (1, 1, 3) pour les anomalies de température.....	58
Figure 7: : QQ-Plot sur les résidus du modèle ARIMA (1,1,3)	58
Figure 8: : Prédiction du modèle ARIMA (1,1,3)	59

Figure 9: : Résidus du modèle ARIMA (2, 2, 3) pour le CO2	61
Figure 10: : QQ-Plot sur les résidus du modèle ARIMA (2,2,3)	62
Figure 11: : Prédiction du modèle ARIMA (2,2,3)	62
Figure 12: : Résidus du modèle ARIMA (2, 2, 0) et QQ-Plot pour le CH4	65
Figure 13: : Prédiction du modèle ARIMA (2,2,0)	66
Figure 14: : Résidus et QQ-Plot sur les résidus du modèle ARIMA (0,2,1)	68
Figure 15: : Prédiction du modèle ARIMA (0,2,1)	69
Figure 16: Pouvoir de Réchauffement global des gaz à effet de serre	91

Introduction

Le développement tel qu'il était conçu à l'échelle de la planète se résumait à l'exploitation des ressources naturelles de la planète et leur transformation en produits destinés à la consommation. Un tel développement ne se préoccupe pas de l'impact sur l'environnement et la santé humaine. Plus de deux décennies d'exploitation des ressources naturelles après la seconde guerre mondiale, des atteintes à l'environnement ont commencé par être dénoncées. On peut citer le fameux rapport Meadows « Halte à la croissance » (Meadows *et al.*, 1969) et le « Printemps silencieux » (Carson, 1962). De même une augmentation globale des températures a été constatée ces dernières décennies (Dufresne et Royer, 2008). L'augmentation des températures entraîne une variabilité climatique dans différentes régions du globe terrestre (Ducharne *et al.*, 2011). Guo *et al.* (2015) avec une approche de modélisation couplé océan-atmosphère combiné au modèle de vagues prédisaient une intensification des tempêtes automnales dans l'Atlantique Nord due aux changements climatiques. Les changements climatiques ont un impact sur les températures et les précipitations (Bedoum *et al.*, 2017).

Les gaz à effet de serre (GES), tels que le dioxyde de carbone (CO_2), le méthane (CH_4), et le protoxyde d'azote (N_2O) provenant de l'émission des industries et de l'automobile sont incriminés dans le réchauffement climatique (Wei et Wang, 2020 ; Shabidul, 2019). Ils jouent un rôle central dans ce phénomène en piégeant la chaleur dans l'atmosphère et en contribuant au réchauffement global (Xin, 2001).

Comprendre et modéliser l'évolution du climat global en lien avec les émissions de gaz à effet de serre (GES) constitue un enjeu majeur pour l'élaboration de stratégies d'atténuation et d'adaptation au changement climatique. Cette étude propose d'appliquer des modèles statistiques de séries temporelles, notamment ARIMA, ARDL, ainsi que des tests de cointégration, afin de capter les dynamiques temporelles et les relations structurelles entre la température globale et les concentrations de GES. Les approches basées sur la volatilité, comme les modèles ARCH, GARCH, ou les méthodes de risque extrême (VaR, EVT), ont également été envisagées, mais leur applicabilité sera réévaluée selon la nature des données.

Ce travail est structuré en cinq chapitres. Le chapitre 1 introduit la problématique, les hypothèses et les objectifs de la recherche. Le chapitre 2 est consacré à la clarification des concepts et à la revue de littérature. Le chapitre 3 présente le cadre géographique, les données et la méthodologie adoptée. Le chapitre 4 expose les résultats empiriques obtenus. Enfin, le

chapitre 5 propose une synthèse générale, discute les limites de l'étude et formule des recommandations.

Chapitre 1 : Problématique, Objectifs et Hypothèses

1.1. Problématique

Le changement climatique est de nos jours une problématique mondiale. Il impacte tous les aspects de la vie humaine et l'environnement physique. Les gaz à effet de serre (GES), notamment le dioxyde de carbone (CO₂), le méthane (CH₄) et le protoxyde d'azote (N₂O), jouent un rôle central dans ce phénomène en retenant la chaleur dans l'atmosphère, intensifiant l'effet de serre naturel, et contribuant ainsi au réchauffement global (Xin, 2001 ; Shabidul, 2019 ; Wei et Wang, 2020).

Les changements climatiques se manifestent par une augmentation des températures moyennes au niveau du globe, une modification des régimes de précipitations, et une fréquence accrue d'événements météorologiques extrêmes tels que les vagues de chaleur, les inondations et les cyclones tropicaux (Arnell *et al.*, 2016 ; IPCC, 2021). Les rapports récents de travaux de recherche confirment que les activités humaines, notamment la combustion des combustibles fossiles et la déforestation, sont les principaux moteurs de l'accumulation des GES dans l'atmosphère (IPCC, 2021).

Les changements climatiques ont des impacts significatifs sur les vivants. Ces impacts varient selon les régions. Selon Morton (2007), les zones côtières subissent une élévation du niveau de la mer et une érosion accrue, tandis que les régions arides et semi-arides font face à des sécheresses plus fréquentes, compromettant ainsi l'accès à l'eau et la sécurité alimentaire. Les systèmes tropicaux, déjà fragiles, quant à eux sont particulièrement vulnérables en raison de leur exposition aux stress climatiques et de leurs capacités limitées d'adaptation (Wheeler et von Braun, 2013).

Le réchauffement climatique est une cause majeure du changement climatique. Selon IPCC (2021), le réchauffement climatique provenant des activités anthropiques a déclenché des changements rapides et généralisés dans l'atmosphère, l'hydrosphère et la biosphère entraînant des perturbations globales du climat.

Le réchauffement global affecte les écosystèmes à toutes les échelles, des processus génétiques aux interactions communautaires. Les espèces modifient leur répartition géographique, leur phénologie, et leurs interactions écologiques pour répondre aux changements environnementaux. Ces ajustements perturbent les réseaux trophiques et les cycles biogéochimiques, menaçant les services écosystémiques cruciaux pour la société humaine (Scheffers *et al.*, 2016). Dans les océans, la hausse des températures provoque un blanchissement massif des coraux, compromettant la biodiversité marine et les moyens de subsistance des communautés côtières (Walther *et al.*, 2002).

Les interactions entre les changements climatiques et la biodiversité révèlent également des effets domino, où la perte d'une espèce peut entraîner des déséquilibres dans les écosystèmes. Par exemple, la réduction des pollinisateurs due aux températures extrêmes pourrait avoir des conséquences désastreuses sur les cultures (Grimm *et al.*, 2013).

Les conséquences des changements climatiques sur les systèmes socio-économiques sont complexes et interdépendantes. L'agriculture, secteur particulièrement sensible aux variations climatiques, fait face à des défis croissants. Une baisse des rendements due aux stress hydriques et thermiques pourrait exacerber l'insécurité alimentaire, en particulier dans les pays en développement (Springmann *et al.*, 2016a,b). Les petits exploitants agricoles, qui dépendent des systèmes de production traditionnels, sont parmi les plus vulnérables en raison de leur capacité limitée à adopter des pratiques d'adaptation (Morton, 2007).

Sur le plan économique, les impacts climatiques sont inégalement répartis. Les économies des pays en développement, souvent plus dépendantes des ressources naturelles, sont plus durement touchées, tandis que les pays industrialisés disposent de ressources pour atténuer les pertes (Tol, 2018).

Le changement climatique pose également des défis significatifs à la santé publique. Les vagues de chaleur prolongées augmentent les risques de maladies cardiovasculaires, tandis que les inondations favorisent la propagation des maladies hydriques comme le choléra. De plus, la répartition géographique des maladies vectorielles, telles que le paludisme et la dengue, est influencée par le réchauffement climatique, exposant de nouvelles populations à ces risques (Haines *et al.*, 2006).

Les effets indirects incluent également l'insécurité alimentaire et la malnutrition, aggravées par des récoltes insuffisantes et la diminution de la qualité des aliments. Les populations des régions

pauvres sont les plus exposées à ces risques, soulignant l'importance de politiques intégrées pour renforcer leur résilience.

Face à l'ampleur des impacts des changements climatiques, des actions globales sont nécessaires pour atténuer ces effets et renforcer la résilience des sociétés et des écosystèmes. Les accords internationaux tels que l'Accord de Paris fournissent un cadre pour limiter les émissions de GES, mais leur mise en œuvre reste inégale. Par ailleurs, l'adaptation aux impacts déjà inévitables nécessite des investissements dans des infrastructures durables, des systèmes de santé renforcés, et des pratiques agricoles résilientes (Carleton et Hsiang, 2016).

L'urgence d'agir est indéniable, car chaque fraction de degré supplémentaire dans le réchauffement global amplifie les impacts négatifs. Investir dans la recherche et l'innovation pour mieux comprendre et anticiper ces effets est un impératif pour construire un avenir résilient face au climat.

Étudier la dynamique et l'évolution du climat est crucial pour comprendre les mécanismes sous-jacents du changement climatique, anticiper ses impacts, et développer des solutions adaptées. Cela contribue à renforcer la résilience des sociétés et des écosystèmes face aux défis croissants du réchauffement climatique. De plus, ces études fournissent une base essentielle pour des politiques climatiques éclairées et des actions concrètes à toutes les échelles, de l'individuel au global.

La nécessité de comprendre et de prédire les changements climatiques repose sur des modèles scientifiques capables de capturer les dynamiques complexes entre les émissions de GES et leurs effets sur le climat global. Plusieurs études se sont penchées sur la question de la dynamique et l'évolution du climat global (Dufresne et Royer, 2008 ; Ducharche *et al.*, 2008 ; Bedoum *et al.*, 2017). Les méthodes utilisées varient selon les chercheurs. Ces méthodes englobent les modèles de circulation générale (Drake, 2014), les méthodes régionaux (Xu *et al.*, 2018), les modèles stochastiques (Navarra *et al.*, 2012), les modèles statistiques (Zhang *et al.*, 1998 ; Dritsaki et Dritsaki, 2020) et l'intelligence artificielle (Nadiga, 2021).

Les modèles ARIMA (AutoRegressive Integrated Moving Average) sont efficaces pour modéliser les tendances et les cycles dans les séries temporelles stationnarisées (Box *et al.*, 2015). Les modèles ARCH et GARCH permettent, quant à eux, de prendre en compte l'hétéroscédasticité conditionnelle, fréquente dans les séries de températures ou d'émissions de GES (Engle, 1982 ; Bollerslev, 1986). Enfin, l'approche Value at Risk (VaR) ainsi que la théorie

des valeurs extrêmes (EVT) offre des outils puissants pour évaluer la probabilité et l'ampleur des événements climatiques rares mais à fort impact (Coles, 2001 ; Driatsaki & Driatsaki, 2020).

Dans cette étude, la modélisation statistique, notamment par le biais des modèles ARIMA (Autoregressive Integrated Moving Average) et ARCH (Autoregressive Conditional Heteroskedasticity), VaR (Value at Risk) et EVT (Extrême Value Theory) et la cointégration sera effectuée. La modélisation statistique offre des outils puissants pour analyser les séries temporelles climatiques et les données sur les GES (Zhang *et al.*, 1998 ; Driatsaki et Driatsaki, 2020).

L'approche ARDL (Autoregressive Distributed Lag) a en revanche la capacité de mettre en évidence une relation de cointégration entre la température globale et les concentrations de Gas à effet de serre (GES), pour ainsi confirmer un lien structurel de long terme ou non entre les émissions anthropiques et le réchauffement climatique (Pesaran *et al.*, 2001).

Comment modéliser statistiquement l'évolution temporelle des émissions de gaz à effet de serre et des variables climatiques majeures, en intégrant à la fois les tendances, la probabilité et les risques extrêmes, afin de produire des projections fiables utiles aux décisions politiques et environnementales ?

Les questions spécifiques de cette recherche sont les suivantes : i) Dans quelle mesure les modèles ARIMA peuvent-ils capturer les tendances temporelles des émissions de GES et des variables climatiques ? ii) Existe-t-il des relations de long terme (cointégration) entre la température et les gaz à effet de serre, et comment les modéliser à l'aide d'un modèle ARDL ? iii) Les séries étudiées présentent-elles une volatilité justifiant l'estimation de modèles ARCH/GARCH ? iv) Quels scénarios de court et moyen terme peut-on établir à partir des modèles statistiques estimés pour les différentes variables climatiques et environnementales ?

1.2. Objectifs de la recherche

1. Tester la stationnarité et déterminer l'ordre d'intégration des séries temporelles climatiques, en vue d'évaluer la possibilité de relations de long terme entre ces variables.

2. Modéliser les séries chronologiques des principales variables climatiques (température globale) et des gaz à effet de serre (CO_2 , CH_4 , N_2O) à l'aide des modèles ARIMA, afin de caractériser leurs tendances temporelles et dynamiques internes.
3. Évaluer l'existence d'une relation de cointégration entre la température globale et les concentrations de CO_2 et CH_4 à l'aide du modèle ARDL, et en interpréter les effets structurels.
4. Produire des projections à court et moyen terme de l'évolution des variables climatiques et environnementales modélisées, en comparant les performances des modèles ARIMA retenus.

1.3. Hypothèses de recherche

- **Hypothèse 1** : Les séries climatiques analysées sont non stationnaires, ce qui nécessite une différenciation préalable pour leur modélisation statistique.
- **Hypothèse 2** : Les modèles ARIMA capturent efficacement les tendances et les dynamiques temporelles des émissions de GES et des anomalies de température globale, et permettent de produire des prévisions fiables à court et moyen termes.
- **Hypothèse 3** : Les résidus des modèles ARIMA présentent de volatilité conditionnelle significative, ce qui rend les approches GARCH, VaR et EVT applicables aux séries utilisées.
- **Hypothèse 4** : Il existe une relation de cointégration à long terme entre les émissions de gaz à effet de serre (notamment le CO_2 et le CH_4) et la température moyenne globale, modélisable à l'aide du cadre ARDL.
- **Hypothèse 5** : Les modèles ARIMA et ARDL, combinés à une analyse rigoureuse des résidus, permettent une compréhension statistique robuste de l'évolution conjointe du climat et des GES.

2. Cadre conceptuel et revue de littérature

2.1. Clarification des concepts

2.1.1. Changement climatique

Le changement climatique désigne des modifications durables des conditions climatiques moyennes, causées à la fois par des phénomènes naturels (oscillations océaniques, cycles solaires, activité volcanique) et surtout anthropiques depuis l'ère industrielle, en raison de la combustion d'énergies fossiles, de la déforestation, ou encore de l'agriculture intensive (IPCC, 2021 ; NASA, 2023). L'effet de serre amplifié par les GES contribue au réchauffement planétaire et aux perturbations climatiques globales.

Depuis l'ère industrielle, les activités humaines, telles que la combustion des combustibles fossiles, la déforestation et l'agriculture intensive, ont entraîné une accumulation rapide de GES dans l'atmosphère. Cette accumulation amplifie l'effet de serre naturel, contribuant au réchauffement de la planète et à des perturbations dans les systèmes climatiques (IPCC, 2021).

2.1.2. Variabilité climatique

Elle se distingue du changement climatique par son caractère transitoire. Les fluctuations interannuelles ou décennales (comme El Niño ou les hivers rigoureux ponctuels) sont des exemples de variabilité naturelle, sans modification systématique à long terme (IPCC, 2021).

Elle se manifeste sur des échelles de temps courtes (mois, années, décennies) et comprend des anomalies, comme des années exceptionnellement chaudes ou froides, sans modification durable des tendances globales.

2.1.3. Gaz à effet de serre

Les GES absorbent le rayonnement infrarouge émis par la Terre et en réémettent une partie vers la surface, réchauffant l'atmosphère (Forster et al., 2007). Le CO₂, principal GES anthropique, est suivi par le CH₄, le N₂O et les gaz fluorés. Leur potentiel de réchauffement global (PRG) diffère : CH₄ ≈ 28 fois plus puissant que CO₂, N₂O ≈ 300 fois, SF₆ ≈ 23 500 fois (IPCC, 2021).

Dioxyde de carbone (CO₂) : Émis principalement par la combustion des combustibles fossiles, la déforestation et certaines activités industrielles.

Méthane (CH₄) : Produit par les activités agricoles (élevage, riziculture), les décharges, et les processus naturels dans les zones humides.

Oxyde d'Azote (N₂O) : Résulte des activités agricoles (utilisation d'engrais azotés) et de certains processus industriels.

Gaz fluorés (HFC, PFC, SF₆) : Émis par des activités industrielles spécifiques, tels que la climatisation et la réfrigération.

2.1.4. Température

Définie comme la mesure de l'agitation moléculaire, la température influence les états physiques des matériaux, les processus biologiques et les phénomènes météorologiques (Young et Freedman, 2019). Dans le contexte climatique, elle est un indicateur clé de l'évolution du climat à l'échelle planétaire.

2.1.5. Anomalies de température

Les anomalies de température désignent les écarts entre les températures observées à un moment donné et une valeur de référence moyenne sur une période climatologique déterminée. Cette période de référence est généralement de 30 ans, comme celle de 1951-1980 ou encore 1981-2010, définie selon les recommandations de l'Organisation météorologique mondiale (OMM). Contrairement aux valeurs absolues, les anomalies permettent de comparer les variations climatiques à différentes échelles spatiales et temporelles, même lorsque les mesures sont prises à partir de réseaux hétérogènes de stations (NASA, 2023 ; NOAA, 2023).

L'analyse des anomalies est particulièrement utile pour détecter les tendances de réchauffement global. La moyenne mondiale des anomalies de température à la surface du globe a dépassé +1,1 °C en 2023 par rapport à l'ère préindustrielle (1850-1900), confirmant une trajectoire ascendante persistante due aux activités anthropiques (IPCC, 2021).

En climatologie, l'utilisation des anomalies est également indispensable pour générer des cartes de réchauffement ou pour modéliser l'évolution temporelle des températures. Ces mesures sont souvent utilisées comme variables dépendantes dans les modèles ARIMA ou GARCH, permettant de capturer à la fois les tendances de long terme et la variabilité interannuelle.

2.1.6. Précipitations

Les précipitations désignent toute forme d'eau, liquide ou solide, qui tombe de l'atmosphère vers la surface terrestre (Pidwirny, 2011 ; IPCC, 2021). Elles incluent différents phénomènes tels que la pluie, la neige, le grésil, la bruine et la grêle. Les précipitations se produisent lorsque la vapeur d'eau dans l'atmosphère se condense en gouttelettes ou en cristaux suffisamment grands pour surmonter les courants ascendants de l'air et atteindre le sol.

2.1.7. Modélisation

La modélisation est une démarche scientifique qui consiste à représenter de manière formalisée un phénomène complexe dans le but d'en faciliter la compréhension, l'analyse, la prédiction ou l'optimisation (Sterman, 2000). Un modèle est une simplification de la réalité, construite à partir d'hypothèses, d'équations ou de règles logiques, afin de capturer les mécanismes essentiels d'un système. Les finalités de la modélisation sont multiples : compréhension, prédiction, optimisation et communication.

Le processus de modélisation suit généralement des étapes bien définies :

- i) Définition du problème et des objectifs,
- ii) Construction du modèle conceptuel ou mathématique,
- iii) Calibrage à partir des données empiriques,
- iv) Validation du modèle (comparaison des prédictions avec des observations),
- v) Simulation et interprétation des résultats.

2.1.7.1. Modèle ARIMA

ARIMA signifie Autoregressive Integrated Moving Average. C'est un modèle statistique utilisé pour analyser et prédire les séries temporelles. Il combine trois composantes principales : l'autorégression (AR), l'intégration (I) et la moyenne mobile (MA). Ce modèle est particulièrement adapté aux séries temporelles stationnaires ou transformées en stationnaires.

Composantes du modèle ARIMA

1. AR (Auto-Regressive) :

La partie AR représente une relation entre une observation et ses valeurs passées.

Elle est caractérisée par le paramètre p , qui indique le nombre de termes passés utilisés pour prédire la valeur actuelle.

2. I (Integrated) :

Le « I » représente le nombre de différenciations nécessaires pour rendre la série stationnaire.

La stationnarité est essentielle pour l'utilisation efficace des modèles ARIMA.

3. MA (Moving Average) :

La partie MA capture la dépendance entre une observation et les erreurs de prédiction des observations passées.

Elle est déterminée par le paramètre q , qui représente le nombre de termes d'erreur passés inclus dans le modèle.

Le modèle ARIMA est noté $ARIMA(p, d, q)$, où :

- p : ordre de la composante AR.
- d : degré de différenciation pour atteindre la stationnarité.
- q : ordre de la composante MA

Ainsi, le modèle ARIMA est noté $ARIMA(p,d,q)$, où chaque composante joue un rôle crucial dans l'explication et la prévision des valeurs futures (Box et Jenkins, 1976 ; Hyndman et Athanasopoulos, 2021).

Les applications du modèle ARIMA sont nombreuses. Elles sont utilisées dans les prévisions économiques et financières (Taux d'intérêt, prix des actions, inflation), l'analyse climatique (Températures, précipitations, concentrations de gaz à effet de serre.), les prévisions démographiques (Croissance de la population), la gestion des stocks (Prévisions de la demande).

2.1.7.2. SARIMA

Le modèle SARIMA (Seasonal Autoregressive Integrated Moving Average) est une extension du modèle ARIMA qui intègre une composante saisonnière. Il est conçu pour analyser et prévoir des séries temporelles présentant des variations cycliques ou saisonnières.

SARIMA est noté $SARIMA(p, d, q)(P, D, Q, s)$, où :

p, d, q : Les paramètres du modèle ARIMA pour la composante non saisonnière :

p : ordre de la partie autorégressive (AR).

d : degré de différenciation pour stationnariser la série.

q : ordre de la partie moyenne mobile (MA).

P, D, Q : Les paramètres pour la composante saisonnière :

P : ordre de la partie autorégressive saisonnière (SAR).

D : degré de différenciation saisonnière.

Q : ordre de la partie moyenne mobile saisonnière (SMA).

s : Périodicité de la saisonnalité (ex. : s=12 pour des données mensuelles avec une saisonnalité annuelle).

SARIMA est particulièrement performant lorsque les données présentent une régularité cyclique (mensuelle, trimestrielle), comme les températures, les ventes saisonnières ou les émissions de gaz à effet de serre avec des cycles annuels (Dritsaki et Dritsaki, 2020 ; Hebsiba Beula et al., 2021).

2.1.7.3. ARCH

Le modèle ARCH (Autoregressive Conditional Heteroskedasticity) est un modèle statistique utilisé pour analyser et prédire la volatilité dans les séries temporelles. Il est particulièrement adapté aux séries où la variance des erreurs n'est pas constante dans le temps (hétéroscédasticité conditionnelle), mais dépend des valeurs passées.

Ce modèle a été proposé par Robert Engle, et il est couramment utilisé en économétrie, finance, et climatologie (Engle, 1982).

Un modèle ARCH (q) peut être décrit par deux composantes :

1. Équation de la série temporelle :

$$y_t = \mu + \varepsilon_t$$

où :

- y_t est la valeur observée à l'instant t ,
- μ est la moyenne conditionnelle,
- ε_t est l'erreur aléatoire, avec $\varepsilon_t = \sigma_t z_t$,
- z_t est une séquence de termes indépendants et identiquement distribués
 $z_t \sim N(0,1)$.

2. Équation de la variance conditionnelle :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_q \varepsilon_{t-q}^2$$

où :

- σ_t^2 est la variance conditionnelle à l'instant t ,
- $\alpha_0 > 0$, et $\alpha_i \geq 0$ pour $i = 1, 2, \dots, q$,
- q est l'ordre du modèle ARCH.

Caractéristiques principales des modèles ARCH

- La variance conditionnelle σ_t^2 dépend des erreurs quadratiques passées ($\varepsilon_{t-1}^2, \varepsilon_{t-2}^2, \dots$).
- Les erreurs actuelles peuvent présenter des périodes de volatilité élevée ou faible, créant des "regroupements de volatilité" observés dans de nombreuses séries temporelles financières ou climatiques.

Étapes de construction d'un modèle ARCH

- i) Identifier les regroupements de volatilité : Analyser les résidus d'une série temporelle pour détecter une variance non constante.
- ii) Estimer les paramètres du modèle ARCH(q) : Utiliser des techniques d'estimation telles que la méthode du maximum de vraisemblance.
- iii) Vérifier les résidus : Les résidus devraient être indépendants et identiquement distribués après modélisation.
- iv) Adapter un modèle GARCH (si nécessaire) : Si un modèle ARCH n'est pas suffisant, une version généralisée (GARCH) peut être utilisée.

Applications du modèle ARCH

Le modèle ARCH est utilisé en :

- i) Finance : Prévoir la volatilité des marchés financiers (prix des actions, taux de change).
- ii) Climatologie : Étudier la variabilité des températures ou des précipitations, notamment lors d'événements extrêmes.
- iii) Économie : Modéliser les fluctuations de variables économiques comme l'inflation ou les taux d'intérêt.

Avantages et limites

Avantages :

- Il capture efficacement la volatilité conditionnelle et les regroupements de volatilité dans les séries temporelles.
- Il est facilement extensible (par exemple, aux modèles GARCH).

Limites :

- Il est inefficace pour les séries présentant une volatilité persistante sur de longues périodes (d'où le recours à GARCH).
- La paramétrisation peut devenir complexe pour des ordres élevés (q).

2.1.7.4. GARCH

Le modèle GARCH (Generalized Autoregressive Conditional Heteroskedasticity) est une généralisation du modèle ARCH, proposé par Bollerslev (1986). Il intègre des dépendances à la fois des variances passées (σ_{t-1}^2) et des erreurs passées (ε_{t-1}^2).

Il est utilisé pour modéliser et prévoir la volatilité conditionnelle dans les séries temporelles présentant des variations de variance au fil du temps (Bollerslev, 1986).

Contrairement au modèle ARCH, le modèle GARCH intègre à la fois : les effets des erreurs passées (comme dans ARCH), et les effets des variances passées.

Cela permet une modélisation plus flexible et efficace des séries temporelles avec une forte persistance de la volatilité.

Structure du modèle GARCH

Un modèle GARCH(p, q) combine les termes :

- q : Les erreurs passées ($\varepsilon_{t-1}^2, \varepsilon_{t-2}^2, \dots$).
- p : Les variances passées ($\sigma_{t-1}^2, \sigma_{t-2}^2, \dots$).

La variance conditionnelle est donnée par :

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2$$

où :

- σ_t^2 : Variance conditionnelle à l'instant t.
- ε_{t-i}^2 : Erreur au carré à l'instant $t - i$.
- σ_{t-j}^2 : Variance conditionnelle passée.
- $\alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0$.

Le modèle GARCH suppose que $\varepsilon_t = \sigma_t z_t$ où z_t suit une distribution normale ou une autre distribution appropriée (par exemple, une distribution t-Student pour capturer des queues épaisses).

Modèle GARCH(1, 1)

Pour un modèle simple GARCH(1, 1) :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

- α_1 capture l'impact des chocs récents (erreurs passées).
- β_1 mesure la persistance de la volatilité (effet mémoire de la variance passée).

Différences entre ARCH et GARCH

- ARCH(q) : Ne prend en compte que les erreurs passées (ε_{t-i}^2) pour modéliser la volatilité.

- GARCH(p, q) : Ajoute les effets des variances passées (σ_{t-j}^2), permettant une meilleure gestion des données présentant une forte persistance de volatilité.

Étapes pour construire un modèle GARCH

- i) Identification : Identifier les regroupements de volatilité dans une série temporelle à l'aide des graphiques des résidus.
- ii) Estimation : Utiliser des méthodes comme le maximum de vraisemblance pour estimer les paramètres (α_i, β_j).
- iii) Validation : Vérifier si les résidus standardisés sont indépendants et identiquement distribués.
- iv) Prévision : Générer des projections de la volatilité future à l'aide du modèle ajusté.

2.2. Revue de littérature

2.2.1. Changements climatiques et Gas à effet de serre

2.2.1.1. Rôle des gaz à effet de serre dans le réchauffement global

Les GES (vapeur d'eau, dioxyde de carbone, méthane, protoxyde d'azote, etc.) présents dans l'atmosphère terrestre permettent à la planète de maintenir une température moyenne d'environ 15 °C. Ils absorbent le rayonnement infrarouge émis par la surface terrestre, le réémettant partiellement vers le sol, ce qui piège la chaleur dans l'atmosphère (IPCC, 2021 ; NASA, 2023). Depuis la révolution industrielle, les activités humaines (combustion des combustibles fossiles, déforestation, agriculture) ont significativement augmenté les concentrations de GES dans l'atmosphère, intensifiant cet effet de serre naturel et entraînant une augmentation des températures moyennes globales (Forster et al., 2021 ; Masson-Delmotte et al., 2021).

2.2.1.2. Impacts des changements climatiques sur les écosystèmes

Les impacts des changements climatiques englobent : l'augmentation des températures moyennes globales, la fonte des glaciers, les impacts sur la biodiversité et les écosystèmes.

Une hausse de 1,1 °C a été enregistrée depuis l'ère préindustrielle (IPCC, 2021). L'intensification de l'effet de serre accélère la fonte des calottes glaciaires et des glaciers, contribuant à une élévation du niveau de la mer. On note une fréquence accrue des vagues de chaleur, des sécheresses, des inondations et des tempêtes, la modification des habitats naturels, migration des espèces, et perte de biodiversité.

2.2.1.3. Impacts des changements climatiques sur les sociétés

Les changements climatiques ont un impact sur différentes composantes de la vie sociétale:

- **Agriculture et sécurité alimentaire** : Les changements climatiques affectent les rendements agricoles par des vagues de chaleur, des sécheresses prolongées et des inondations. Des cultures dépendantes de conditions climatiques spécifiques, comme le blé ou le riz, sont particulièrement vulnérables, aggravant l'insécurité alimentaire (Springmann *et al.*, 2016a,b).
- **Catastrophes naturelles** : Les événements climatiques extrêmes (ouragans, inondations) provoquent des pertes économiques massives, endommageant les infrastructures et perturbant les chaînes d'approvisionnement. Les coûts de reconstruction post-catastrophe augmentent les pressions sur les économies locales et nationales.
- **Industries et tourisme** : Le secteur du tourisme est affecté par des conditions météorologiques imprévisibles et la perte d'attractions naturelles (comme la fonte de glaciers et les récifs coralliens). L'énergie, notamment l'hydroélectricité, est vulnérable à la variabilité des régimes hydrologiques.
- **Santé** : L'expansion des maladies vectorielles (comme le paludisme ou la dengue) est favorisée par le réchauffement global et l'allongement des saisons de transmission (Haines *et al.*, 2006). L'augmentation des températures expose les populations à des vagues de chaleur intenses, augmentant les risques de déshydratation, d'accidents vasculaires cérébraux et de mortalité liée à la chaleur.

La baisse des rendements agricoles affecte directement la disponibilité des aliments, entraînant des cas croissants de malnutrition, notamment chez les enfants. Les événements climatiques extrêmes, comme les ouragans ou les inondations, causent des traumatismes psychologiques et des troubles mentaux.

2.2.2. Interaction entre composantes des écosystèmes et les GES

- Atmosphère et circulation générale :

L'augmentation des gaz à effet de serre (GES) modifie les gradients de température entre l'équateur et les pôles, ce qui influence les régimes de vents ainsi que les courants-jets (jet streams). Ces altérations affectent en retour les systèmes météorologiques à grande échelle, notamment les cyclones tropicaux et les moussons (Masson-Delmotte et al., 2021 ; Trenberth, 2011).

- Océans et échanges thermiques :

Les océans absorbent environ 90 % de la chaleur supplémentaire générée par l'effet de serre renforcé, retardant temporairement le réchauffement global. Les gaz dissous, comme le CO₂, interagissent avec les océans, entraînant l'acidification des eaux et affectant la faune marine (Hoegh-Guldberg et al., 2018).

- Cryosphère et élévation du niveau de la mer :

Le réchauffement dû aux GES accélère la fonte des calottes glaciaires et des glaciers, contribuant à une élévation du niveau de la mer (IPCC, 2021). Ces changements perturbent les habitats des écosystèmes arctiques et augmentent les risques d'inondations côtières.

- Biosphère et flux de carbone :

Les écosystèmes terrestres (forêts, sols) agissent comme des puits de carbone, absorbant environ 30 % des émissions de CO₂. Cependant, le réchauffement global limite cette capacité (IPCC, 2021). Les GES influencent les cycles biologiques des plantes et des animaux, modifiant leur répartition géographique et leur phénologie (Scheffers et al., 2016).

2.2.3. Modélisation statistique des séries temporelles climatiques

2.2.3.1. Modèles ARIMA et SARIMA pour modéliser le climat

ARIMA est une méthode puissante pour analyser les séries temporelles avec des tendances et des fluctuations saisonnières. Elle est largement utilisée pour prédire les températures mondiales et les variations saisonnières et simuler les émissions futures de GES en fonction des données historiques.

Par exemple, une étude récente utilisant ARIMA a démontré sa capacité à prédire les températures mondiales sur une période de 5 à 10 ans avec une précision élevée (Hebsiba Beula et al., 2021).

Plusieurs études ont démontré l'efficacité du modèle SARIMA dans la modélisation du climat.

Hebsiba Beula et al. (2021) ont utilisé un modèle SARIMA pour prédire les températures mensuelles en Inde. Les résultats ont montré une capacité prédictive élevée, particulièrement lorsqu'il existe une forte saisonnalité dans les données.

Dritsaki et Dritsaki (2020) ont appliqué un modèle SARIMA pour estimer les émissions de CO₂ dans l'Union européenne, démontrant sa pertinence pour prévoir des indicateurs environnementaux corrélés au climat.

2.2.4. Volatilité dans les séries temporelles et analyse

2.2.4.1. Modèle ARCH et GARCH pour modéliser le climat

Les modèles ARCH et leurs variantes (GARCH) se distinguent par leur capacité à analyser les fluctuations irrégulières dans les données climatiques, comme les pics soudains de températures ou les variations saisonnières extrêmes des émissions de GES. Ces modèles complètent ARIMA en s'attaquant aux incertitudes liées à la volatilité conditionnelle (Dritsaki et Dritsaki, 2020).

2.2.4.2. Modélisation des chocs liés aux événements climatiques extrêmes

2.2.4.2.1. Value at Risk

L'approche Value-at-Risk (VaR), initialement développée dans le domaine financier pour quantifier les pertes maximales attendues sous un certain niveau de confiance, est aujourd'hui appliquée à l'analyse des risques climatiques extrêmes (Jorion, 2006). Cette méthode permet d'estimer la valeur seuil que des variables climatiques, telles que la température ou les précipitations, ne devraient pas dépasser dans un certain intervalle de temps, avec un niveau de confiance donné. Par exemple, on peut utiliser la VaR pour prédire, avec 95 % de probabilité, la température maximale journalière qui ne sera pas excédée dans une région donnée, ce qui est particulièrement utile pour la planification agricole, la santé publique ou la gestion des infrastructures exposées à la chaleur extrême. Cette approche offre un cadre rigoureux pour intégrer les événements rares dans la gestion des risques climatiques, en particulier lorsque les extrêmes peuvent avoir des conséquences disproportionnées.

2.2.4.2.2. Extrême Value Theory

L'un des objectifs majeurs de la théorie des valeurs extrêmes (Extreme Value Theory - EVT) est de modéliser de manière explicite la probabilité et l'intensité des événements rares, tels que les vagues de chaleur extrême, les précipitations torrentielles ou les sécheresses exceptionnelles (Coles, 2001). Cette approche repose sur deux cadres principaux. La première est l'approche des maxima par bloc, qui consiste à diviser la série temporelle en sous-périodes (mois, années) et à en extraire les valeurs maximales, modélisées ensuite à l'aide de distributions asymptotiques telles que Gumbel, Fréchet ou Weibull. La seconde est l'approche des excès de seuil, fondée sur la Generalized Pareto Distribution (GPD), qui modélise les observations dépassant un certain seuil critique. Cette dernière est particulièrement utile lorsque l'on souhaite exploiter pleinement les données extrêmes sans perdre d'information en se limitant à un seul maximum par bloc (Coles, 2001). Ces méthodes sont idéales pour quantifier des seuils critiques dans le contexte climatique, comme des températures dépassant 40 °C ou des précipitations journalières supérieures à 100 mm, fournissant ainsi une base robuste pour l'analyse de la vulnérabilité climatique et la planification de mesures d'adaptation.

2.2.5. Apprentissage automatique et modélisation du climat

Des approches hybrides intégrant ARIMA et ARCH avec d'autres techniques (réseaux neuronaux, par exemple) permettent d'améliorer la précision des prévisions climatiques et de mieux saisir les incertitudes (Liu *et al.*, 2024).

L'apprentissage automatique (machine learning) représente une avancée majeure dans la modélisation du climat, en complément des approches traditionnelles comme les modèles ARIMA, GARCH ou les modèles de circulation générale (GCMs). Ces méthodes permettent d'extraire automatiquement des relations complexes et non linéaires à partir de grandes quantités de données climatiques, souvent multivariées, bruyantes et hétérogènes.

Les méthodes d'apprentissage automatique utilisées dans le climat sont :

i) Réseaux de neurones artificiels (ANN)

Ils Capables d'apprendre des relations complexes entre variables climatiques et sont utilisés pour prédire des variables comme la température, les précipitations ou les concentrations de CO₂.

Les réseaux de neurones artificiels (ANN) combiné à un prétraitement ARIMA peuvent être utilisés pour modéliser la température mensuelle (Hebsiba Beula *et al.*, 2021).

ii) Réseaux de neurones convolutifs (CNN)

Ils sont adaptés aux données spatiales (cartes climatiques, images satellites) et utilisés pour détecter des motifs dans la distribution spatiale des températures ou des précipitations (Chattopadhyay et al., 2020 ; Rakotoarimanana et al., 2025).

iii) Réseaux de neurones récurrents (RNN) et LSTM (Long Short-Term Memory)

Ils sont spécialisés dans les données séquentielles et très performants pour prédire les séries temporelles climatiques et intégrer la mémoire des événements passés (Chakraborty, 2023).

iv) Forêts aléatoires (Random Forests) et méthodes d'ensemble (boosting)

Ils ont d'excellentes performances pour la classification et la régression climatique et sont utilisées pour la prévision de la fréquence des événements extrêmes ou pour estimer la sensibilité climatique régionale (Hermann et Schumacher, 2018).

v) Systèmes hybrides (ARIMA-ANN, GARCH-RF)

Les systèmes hybrides visent à tirer parti des forces complémentaires des approches statistiques classiques et des modèles d'intelligence artificielle (IA). Par exemple, Zhang (2003) propose un modèle combinant ARIMA et réseaux de neurones artificiels (ANN), dans lequel l'ARIMA capture la structure linéaire des séries temporelles tandis que l'ANN modélise les composantes non linéaires. Ce modèle hybride améliore considérablement la précision des prévisions. De manière similaire, Babaria et Florescu (2025) développent une architecture GARCH-Random Forest, où la volatilité conditionnelle estimée par un modèle GJR-GARCH est utilisée comme entrée pour une forêt aléatoire. Cette approche améliore la capacité prédictive, notamment dans les contextes financiers où la variance change dans le temps.

2.2.6. Cointégration

L'analyse de la cointégration permet d'identifier des relations d'équilibre de long terme entre plusieurs séries temporelles non stationnaires individuellement, mais évoluant de manière conjointe (Engle et Granger, 1987). En effet, si deux séries sont intégrées d'ordre un ($I(1)$) et qu'une combinaison linéaire de celles-ci est stationnaire, alors elles sont dites cointégrées.

Dans les domaines climatique et environnemental, cette notion est pertinente pour étudier des variables telles que les températures, les concentrations de gaz à effet de serre et les

précipitations, qui suivent souvent des trajectoires non stationnaires mais présentent des liens structurels à long terme.

Trois approches principales permettent de tester la cointégration : i) Test d'Engle-Granger (Engle et Granger, 1987), ii) Test de Johansen, iii) Test des bornes dans l'approche ARDL.

Le test d'Engle-Granger (1987)

Proposé par Engle et Granger (1987), ce test repose sur une approche en deux étapes. Il s'applique à deux séries temporelles $I(1)$. La première étape consiste à estimer par régression linéaire ordinaire (OLS) la relation entre les deux variables en niveau. La deuxième étape applique un test de stationnarité (comme le test ADF) aux résidus de cette régression. Si les résidus sont stationnaires, cela signifie que les deux séries sont cointégrées.

Cette méthode est simple à mettre en œuvre, mais elle souffre de plusieurs limitations : elle ne permet d'évaluer qu'une seule relation de cointégration et ne fonctionne que pour deux variables. De plus, elle est sensible aux erreurs d'estimation dans la première étape (problème de superposition).

Le test de Johansen (1988, 1991)

L'approche de Johansen généralise celle d'Engle-Granger en permettant l'analyse de plusieurs relations de cointégration dans un système multivarié. Le test repose sur une estimation du modèle VAR (Vector Autoregressive) sous forme réduite, puis sur une analyse de la matrice des coefficients via les valeurs propres. Deux statistiques sont proposées : le trace test et le maximum eigenvalue test. Le test permet de déterminer à la fois le rang de cointégration et les vecteurs de cointégration.

Le test de Johansen est plus puissant et rigoureux, notamment en présence de trois variables ou plus, mais il exige que toutes les séries soient intégrées d'ordre un ($I(1)$), ce qui doit être vérifié au préalable.

Le test des bornes dans l'approche ARDL (Pesaran et al., 2001)

L'approche ARDL (AutoRegressive Distributed Lag) développée par Pesaran, Shin et Smith (2001) permet de tester la cointégration entre des variables pouvant être $I(0)$ et/ou $I(1)$, ce qui offre une plus grande flexibilité que les approches précédentes. Elle est particulièrement adaptée aux petits échantillons et aux contextes où les variables n'ont pas nécessairement le même ordre d'intégration.

Le test des bornes (Bounds test) repose sur l'estimation d'un modèle ARDL, suivi d'un test F sur l'ensemble des coefficients de long terme. Deux bornes critiques sont proposées : l'une pour le cas où toutes les variables sont $I(0)$, l'autre pour $I(1)$. Si la statistique F dépasse la borne supérieure, la cointégration est confirmée.

Ce test est donc très pertinent dans les études empiriques en climatologie ou économie environnementale, où la structure d'intégration peut être mixte.

2.2.7. Lien entre économie et changement climatique

Le changement climatique et l'économie entretiennent une relation profondément interconnectée et bidirectionnelle. D'une part, les activités économiques constituent l'une des principales sources d'émissions de gaz à effet de serre (GES), qui contribuent au réchauffement climatique ; d'autre part, les impacts du changement climatique engendrent des conséquences économiques significatives, en affectant la croissance, les investissements, la productivité et la stabilité des systèmes socio-économiques à l'échelle mondiale (Stern, 2007 ; IPCC, 2022 ; OECD, 2015).

2.2.7.1. L'économie comme moteur du changement climatique

L'économie joue un rôle central en tant que moteur du changement climatique. Les activités industrielles, les transports, l'agriculture intensive et l'exploitation des ressources naturelles sont à l'origine d'émissions massives de gaz à effet de serre (GES), principalement de dioxyde de carbone (CO_2), de méthane (CH_4) et de protoxyde d'azote (N_2O). Le modèle économique fondé sur une croissance continue et une forte dépendance aux énergies fossiles intensifie la pression exercée sur les systèmes climatiques. Selon le sixième rapport d'évaluation du Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC), les émissions anthropiques sont responsables de la quasi-totalité du réchauffement climatique observé depuis l'ère préindustrielle (IPCC, 2021). Par ailleurs, les travaux de Nordhaus (2019), prix Nobel d'économie, ont démontré que l'activité économique engendre des rétroactions climatiques à travers la consommation énergétique, les changements d'usage des sols et les émissions industrielles.

2.2.7.2. Les impacts économiques du changement climatique

2.2.7.2.1. Réduction de la productivité agricole

Le changement climatique a des répercussions notables sur la productivité agricole, en particulier à travers l'intensification des vagues de chaleur, l'augmentation de la fréquence et de la gravité des sécheresses, ainsi que la multiplication des événements météorologiques extrêmes. Ces perturbations compromettent la stabilité des rendements agricoles, menaçant ainsi la sécurité alimentaire mondiale. Elles contribuent également à l'augmentation des prix des denrées alimentaires et fragilisent les économies rurales, en particulier dans les pays en développement où l'agriculture représente une part substantielle du PIB et de l'emploi (Springmann et al., 2016a,b).

2.2.7.2.2. Hausse des coûts liés aux catastrophes naturelles

La multiplication des catastrophes naturelles telles que les inondations, cyclones, incendies de forêt et sécheresses, entraîne des pertes économiques considérables. Ces événements provoquent la destruction d'infrastructures, la perte de récoltes agricoles et le déplacement de populations, avec des conséquences durables sur les économies locales et nationales. Les coûts induits par ces catastrophes pèsent lourdement sur les finances publiques, notamment à travers l'augmentation des dépenses d'urgence, de reconstruction, et d'investissement dans les infrastructures de résilience (Bangalore et al., 2016 ; IPCC, 2022).

2.2.7.2.3. Effets sur la santé et la main-d'œuvre

Le changement climatique contribue à l'augmentation de la prévalence des maladies climato-sensibles telles que le paludisme, la dengue, les diarrhées et les pathologies liées au stress thermique. Ces maladies sont sensibles aux conditions météorologiques, notamment aux températures élevées et aux précipitations extrêmes, qui influencent la survie et la reproduction des vecteurs pathogènes (IPCC, 2022 ; WHO, 2021). Par exemple, le paludisme est en expansion vers des zones auparavant non endémiques en raison du réchauffement des températures, notamment dans les régions d'altitude en Afrique de l'Est (Caminade et al., 2014).

Ces effets sur la santé ont un impact direct sur la main-d'œuvre : la morbidité réduit la productivité, en particulier dans les secteurs manuels et exposés au climat, comme l'agriculture et la construction (Kjellstrom et al., 2009). Par ailleurs, l'aggravation de l'incidence des maladies entraîne une hausse des dépenses de santé, tant publiques que privées, alourdissant la charge des systèmes sanitaires, surtout dans les pays à faibles revenus où les infrastructures sont souvent insuffisantes (Haines et al., 2006a ; Haines et al., 2006b ; WHO, 2021).

2.2.7.2.4. Risques pour la stabilité macroéconomique

Les chocs climatiques, tels que les sécheresses prolongées, les inondations, ou les tempêtes extrêmes, ont des conséquences macroéconomiques profondes. En perturbant les chaînes d'approvisionnement, ils entraînent des ruptures de production, des pénuries de biens et des retards logistiques, ce qui peut engendrer une hausse de la volatilité des prix, notamment dans les secteurs agroalimentaires et énergétiques (IPCC, 2022 ; Boehm et al., 2019). Ces perturbations affectent aussi les échanges commerciaux, provoquant des déséquilibres dans les balances courantes, surtout pour les pays exportateurs de matières premières.

Les marchés financiers peuvent également être affectés par l'incertitude climatique. Une fréquence accrue de catastrophes naturelles induit une revalorisation à la baisse des actifs exposés, un accroissement des primes de risque, et une réduction de la confiance des investisseurs, en particulier dans les économies vulnérables (Batten et al., 2016). Par conséquent, les flux d'investissements directs étrangers (IDE) peuvent être détournés vers des régions perçues comme plus stables sur le plan environnemental. Les finances publiques sont aussi fragilisées par l'augmentation des dépenses d'adaptation et de reconstruction, réduisant ainsi les marges de manœuvre budgétaires (IMF, 2020).

Ces dynamiques mettent en lumière le lien entre changement climatique et stabilité macroéconomique, appelant à une intégration systématique du risque climatique dans les politiques économiques et financières nationales et internationales.

2.2.7.3. Instruments économiques pour lutter contre le changement climatique

2.2.7.3.1. Taxe carbone et marché du carbone

La taxe carbone et les marchés du carbone sont deux instruments économiques clés de la politique climatique, conçus pour internaliser les externalités négatives associées aux émissions de gaz à effet de serre (GES). Selon le principe du pollueur-payeur issu de la théorie économique de Pigou, ces instruments visent à intégrer le coût social du carbone dans les décisions économiques des agents (Pigou, 1920 ; Stiglitz et al., 2017).

La taxe carbone consiste à imposer un prix fixe sur chaque tonne de CO₂ émise, incitant ainsi les entreprises et les ménages à réduire leurs émissions en modifiant leurs comportements de production et de consommation. Cette approche présente l'avantage de fournir une incitation

constante à innover dans des technologies propres, tout en générant des recettes fiscales pouvant être redistribuées ou utilisées pour financer la transition énergétique (OECD, 2019).

En parallèle, les marchés du carbone, tels que le système d'échange de quotas d'émission (ETS-Emissions Trading System), établissent un plafond global d'émissions, que les entreprises participantes peuvent échanger sous forme de permis. Ce système crée un signal-prix pour le carbone tout en assurant un contrôle quantitatif sur les émissions globales. L'Union européenne, par exemple, exploite l'un des plus vastes systèmes de ce type (EU ETS), considéré comme un modèle en matière de tarification du carbone (Ellerman et al., 2014).

Ces instruments ont pour finalité commune d'orienter les décisions économiques vers des trajectoires bas-carbone, en rendant les choix polluants plus coûteux que les alternatives durables.

2.2.7.3.2. Subventions vertes et investissements durables

Les subventions vertes et les investissements durables sont des leviers essentiels pour accélérer la transition vers une économie bas-carbone. Les gouvernements utilisent ces outils pour soutenir le développement des énergies renouvelables (solaire, éolien, biomasse), améliorer l'efficacité énergétique des bâtiments et des transports, et encourager la recherche-développement dans les technologies propres. Ce soutien public permet de réduire les coûts de déploiement des technologies vertes, de lever les barrières à l'entrée sur les marchés et de stimuler l'innovation environnementale (IEA, 2022 ; Acemoglu et al., 2012).

En injectant des fonds publics dans les infrastructures durables et les secteurs verts, les États peuvent générer des effets multiplicateurs économiques tout en réduisant les émissions de GES. Par exemple, l'Union européenne a intégré des critères de durabilité environnementale dans sa taxonomie verte et son plan de relance post-COVID (NextGenerationEU), orientant ainsi les flux financiers vers les activités favorables au climat (European Commission, 2021).

De plus, des études en économie de l'innovation montrent que les politiques de soutien ciblées, combinées à des signaux-prix comme une taxe carbone, permettent de réorienter durablement les trajectoires technologiques vers des modèles plus sobres en carbone (Acemoglu et al., 2012 ; Aghion et al., 2016).

2.2.7.4. Évaluation économique des politiques climatiques

L'évaluation économique des politiques climatiques repose essentiellement sur des analyses coût-bénéfice (ACB), qui permettent de comparer les coûts des mesures d'atténuation et d'adaptation aux bénéfices socio-économiques futurs liés à la réduction des impacts climatiques. Ces analyses sont cruciales pour orienter les décisions publiques, en identifiant les stratégies les plus efficaces économiquement pour limiter le réchauffement et renforcer la résilience des sociétés (Nordhaus, 1994 ; IPCC, 2022).

Le rapport Stern (2006), l'un des plus influents dans ce domaine, a démontré que les coûts d'une action rapide pour stabiliser les émissions de GES (environ 1 % du PIB mondial annuel à l'époque) sont largement inférieurs aux pertes économiques potentielles induites par l'inaction, estimées entre 5 % et 20 % du PIB mondial par an. Ce rapport a transformé la perception du changement climatique, le présentant non seulement comme un défi environnemental, mais aussi comme une menace majeure pour la croissance économique mondiale et la stabilité financière.

Les ACB utilisent souvent des modèles intégrés (Integrated Assessment Models, IAMs), tels que DICE (Dynamic Integrated model of Climate and the Economy) de Nordhaus, pour simuler les interactions entre économie et climat à long terme. Ces modèles intègrent des hypothèses sur la croissance, la démographie, l'évolution des émissions, les dommages climatiques, et les technologies d'atténuation, afin de calculer la trajectoire optimale de politique climatique (Nordhaus, 2017).

2.2.7.5. Inégalités économiques face au climat

Le changement climatique exacerbe les inégalités économiques, tant entre pays qu'au sein des populations. Les pays à faibles revenus, en particulier ceux situés dans les zones tropicales ou subtropicales, sont les plus exposés aux aléas climatiques tels que les sécheresses, inondations, cyclones ou élévation du niveau de la mer. Paradoxalement, ces pays ont historiquement émis très peu de gaz à effet de serre, mais en subissent les conséquences les plus graves (IPCC, 2022 ; Roberts et Parks, 2007).

À l'échelle nationale, ce sont souvent les populations les plus pauvres, notamment dans les zones rurales dépendantes de l'agriculture de subsistance ou dans les zones côtières informelles, qui sont les plus vulnérables. Ces groupes disposent de peu de capital économique, technique ou institutionnel pour adapter leurs moyens de vie aux changements climatiques, ce qui amplifie les risques de perte de revenus, de santé dégradée et de déplacements forcés (Bangalore et al.,

2016). Cette vulnérabilité accrue alimente un cercle vicieux de pauvreté climatique, accentuant les inégalités sociales et territoriales (Islam et Winkel, 2017).

Les politiques climatiques doivent donc intégrer une approche distributive, en tenant compte de la justice climatique, pour assurer une transition juste et inclusive. Cela implique des mécanismes de compensation, de financement climatique, et de renforcement des capacités dans les pays en développement.

2.2.7.6. Perspectives vers une économie résiliente et bas-carbone

La relation bidirectionnelle entre économie et changement climatique appelle à une transformation structurelle des modèles de développement. Pour répondre à la crise climatique tout en assurant une croissance soutenable, les économistes et décideurs plaident pour l'émergence d'une économie résiliente et bas-carbone, articulée autour de plusieurs piliers interdépendants.

Premièrement, la transition vers des systèmes de production circulaires fondés sur la réduction, la réutilisation, le recyclage et l'éco-conception permet de minimiser l'empreinte écologique tout en conservant la valeur des ressources dans le temps (Ellen MacArthur Foundation, 2013). Une telle approche réduit les émissions de GES tout en créant de nouvelles chaînes de valeur.

Deuxièmement, la valorisation du capital naturel incluant l'eau, la biodiversité, les sols et les forêts est essentielle pour intégrer la durabilité écologique dans les politiques économiques. Des outils tels que la comptabilité du capital naturel ou les paiements pour services écosystémiques (PSE) permettent d'internaliser la contribution des écosystèmes à la richesse économique (Dasgupta, 2021).

Troisièmement, il est nécessaire de dépasser le produit intérieur brut (PIB) comme unique indicateur de performance économique. Des indicateurs alternatifs, comme l'Indice de développement humain ajusté aux inégalités (IDHI), l'Indice de bien-être économique durable (ISEW), ou les tableaux de bord verts de l'OCDE, permettent d'intégrer les dimensions environnementales, sociales et de gouvernance (Stiglitz, Sen & Fitoussi, 2009).

Par ailleurs, les investissements climatiques sont désormais perçus non plus comme un coût, mais comme une opportunité économique. Selon l'Agence Internationale de l'Énergie (IEA, 2022), chaque dollar investi dans la transition énergétique propre génère plus d'emplois que les investissements dans les énergies fossiles. Ils stimulent l'innovation technologique, renforcent la sécurité énergétique et réduisent les vulnérabilités macroéconomiques.

Le changement climatique ne constitue donc pas seulement une crise environnementale, mais représente une menace systémique pour l'économie mondiale, affectant les chaînes d'approvisionnement, les marchés financiers, les budgets publics et la stabilité sociale (WEF, 2023). Inversement, les politiques économiques ont un rôle décisif à jouer dans l'atténuation du réchauffement global. Une coordination étroite entre les politiques économiques, environnementales et sociales s'impose pour bâtir une économie inclusive, résiliente et durable à long terme.

3. Méthodologie

Cette section décrit les méthodes empiriques utilisées pour analyser les dynamiques temporelles entre les variables climatiques : l'anomalie de température annuelle, la concentration de dioxyde de carbone (CO₂), de méthane (CH₄) et de protoxyde d'azote (N₂O). Ces données ont été obtenues à partir de bases de données internationales telles que la NOAA, la NASA, et le GIEC.

L'approche méthodologique repose principalement sur l'analyse de séries temporelles via des tests de stationnarité, des modèles ARIMA et ARDL, ainsi que sur des tests de diagnostic des résidus.

3.1. Description des données

L'analyse repose sur quatre séries temporelles climatiques couvrant différentes périodes historiques. Ces données ont été extraites de sources officielles reconnues telles que la NOAA (National Oceanic and Atmospheric Administration) et le GISS/NASA (Goddard Institute for Space Studies). Les variables retenues pour l'étude sont : l'anomalie de température globale annuelle, la concentration atmosphérique de dioxyde de carbone (CO₂), de méthane (CH₄) et de protoxyde d'azote (N₂O).

Température globale

- Période couverte : 1880 à 2024
- Source : NASA GISS
- Unité : Anomalie en °C par rapport à la moyenne de référence (1951–1980)
- Segment utilisée : 1880–2015 (apprentissage), 2016–2024 (test)

Dioxyde de carbone (CO₂)

- Période couverte : 1974 à 2024
- Source : NOAA ESRL (Mauna Loa Observatory)
- Unité : Parties par million (ppm)
- Segment utilisée : 1974–2018 (apprentissage), 2019–2024 (test)

Méthane (CH₄)

- Période couverte : 1984 à 2023

- Source : NOAA GML (Global Monitoring Laboratory)
- Unité : Parties par milliard (ppb)
- Segment utilisée : 1984–2015 (apprentissage), 2016–2023 (test)

Protoxyde d’azote (N₂O)

- Période couverte : 2001 à 2023
- Source : NOAA GML
- Unité : Parties par milliard (ppb)
- Segment utilisée : 2001–2021 (apprentissage), 2022–2023 (test)

3.2. Prétraitement des données

L’ensemble des séries a été importé et traité à l’aide du logiciel R, en mobilisant plusieurs packages adaptés à l’analyse de séries temporelles climatiques :

- readxl : pour l’importation de fichiers Excel (notamment les séries N₂O extraites manuellement).
- tidyverse (incluant dplyr, ggplot2, tidyr) : pour le nettoyage, la transformation et la visualisation des données.
- lubridate : pour la gestion des dates.
- zoo et xts : pour manipuler les séries temporelles.
- forecast : pour estimer les modèles ARIMA et effectuer les prévisions.
- tseries et urca : pour les tests de stationnarité (ADF).
- FinTS : pour les tests ARCH (volatilité conditionnelle).
- ARDL : pour l’estimation automatique de modèles ARDL et le test de co-intégration par bornes.
- ggfortify : pour l’affichage graphique intégré des modèles statistiques.

Les jeux de données ont été harmonisés en fréquence annuelle, nettoyés des valeurs manquantes, et combinés en une base commune au format panel. Les variables non numériques ont été transformées, et les anomalies de température ont été alignées sur les concentrations de gaz pour permettre une modélisation conjointe dans le cadre de la cointégration.

3.3. Tests de stationnarité

La stationnarité est une condition essentielle dans l'analyse des séries temporelles, notamment pour l'estimation de modèles ARIMA et ARDL (Enders, 2015 ; Hamilton, 1994).. Une série est dite stationnaire lorsque sa moyenne, sa variance et son autocorrélation ne varient pas dans le temps. En présence de non-stationnarité, les inférences statistiques deviennent peu fiables, et une transformation par différenciation est nécessaire pour stabiliser la série (Gujarati et Porter, 2009).

Les tests de stationnarité ont été réalisés à l'aide du test de Dickey-Fuller augmenté (ADF), qui permet de détecter la présence d'une racine unitaire dans une série temporelle (Dickey et Fuller, 1979). Le test ADF a été mis en œuvre dans R via le package tseries à l'aide de la fonction `adf.test()`, ainsi que dans certains cas avec `ur.df()` du package urca pour confirmer les résultats.

Le test ADF repose sur l'estimation d'une équation de régression du type :

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t$$

- H_0 : la série possède une racine unitaire (non stationnaire).
- H_1 : la série est stationnaire.

Le test examine si le coefficient γ est significativement différent de zéro. Si la p-value est inférieure à 5 %, l'hypothèse nulle est rejetée, ce qui signifie que la série est stationnaire.

3.4. Modélisation ARIMA

Les modèles ARIMA (AutoRegressive Integrated Moving Average) ont été utilisés pour modéliser et prévoir l'évolution individuelle de chaque série climatique (anomalie de température, CO₂, CH₄, N₂O), en tenant compte de leurs propriétés de stationnarité. Ces modèles permettent de capturer à la fois les composantes de tendance, d'autocorrélation et de bruit aléatoire dans une série temporelle.

3.4.1. Structure générale d'un modèle ARIMA

Un modèle ARIMA est défini par trois paramètres : (p, d, q) , où :

- p : ordre du processus autorégressif (AR),
- d : nombre de différenciations nécessaires pour stationnariser la série (intégration),
- q : ordre du processus de moyenne mobile (MA).

L'équation générale du modèle peut s'écrire :

$$\Phi(L)(1 - L)^d y_t = \Theta(L)\varepsilon_t$$

où L est l'opérateur de retard, $\Phi(L)$ est le polynôme autorégressif, et $\Theta(L)$ le polynôme de moyenne mobile (Box et al., 2015). Cette formulation permet de représenter des processus dynamiques complexes tout en capturant les dépendances temporelles et les chocs transitoires.

3.4.2. Procédure d'estimation

L'estimation des modèles ARIMA a été réalisée à l'aide du langage R, principalement avec le package forecast (Hyndman et Athanasopoulos, 2021). La procédure a suivi les étapes suivantes :

- Identification de la stationnarité :

Le test de Dickey-Fuller augmenté (ADF) a été appliqué pour déterminer le degré de différenciation nécessaire à chaque série (voir section 3.3). Ce test a permis d'identifier les séries intégrées d'ordre 1 ou 2, condition préalable à la spécification d'un modèle ARIMA.

- Sélection automatique du modèle :

La fonction `auto.arima()` a été utilisée pour sélectionner automatiquement les paramètres p et q , en minimisant les critères d'information AIC, AICc et BIC (Hyndman et Athanasopoulos, 2021). Cette approche permet une identification efficace du meilleur modèle parmi un ensemble de combinaisons possibles.

- Estimation manuelle complémentaire :

Certains modèles ont été testés manuellement avec la fonction `Arima()` afin de valider les résultats obtenus automatiquement ou pour explorer d'autres spécifications jugées économiquement ou physiquement plausibles.

- Évaluation des résidus :

Chaque modèle a fait l'objet d'une analyse diagnostique rigoureuse :

- i) Le test de Ljung-Box a permis de vérifier l'absence d'autocorrélation résiduelle, condition nécessaire pour considérer les résidus comme un bruit blanc (Box et al., 2015).
- ii) Le test ARCH a été utilisé pour détecter une éventuelle hétéroscédasticité conditionnelle, signe d'instabilité de la variance (Tsay, 2010).

iii) La normalité des résidus a été testée via le test de Jarque-Bera.

- Validation hors échantillon :

Pour évaluer les capacités prédictives des modèles, des prévisions ont été réalisées sur des périodes de test (généralement 2016–2023), selon les séries disponibles. Les performances ont été mesurées à l'aide de plusieurs métriques standards : RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), MASE (Mean Absolute Scaled Error) et Theil's U (Hyndman & Athanasopoulos, 2021).

3.5. Tests sur les résidus

Après l'estimation des modèles ARIMA, il est indispensable de vérifier la validité statistique des résultats via une analyse des résidus. L'objectif est de s'assurer que les résidus (les erreurs du modèle) se comportent comme un bruit blanc, c'est-à-dire qu'ils sont non corrélés, de moyenne nulle, et de variance constante (Box et al., 2015 ; Tsay, 2010). Cette étape garantit que le modèle a bien capturé la dynamique de la série et qu'il n'existe pas de structure laissée inexpliquée.

3.5.1. Test de Ljung-Box (autocorrélation résiduelle)

Le test de Ljung-Box a été appliqué aux résidus de chaque modèle pour tester l'absence d'autocorrélation. Il vérifie si les autocorrélations des résidus jusqu'à un certain lag sont significativement différentes de zéro.

- Hypothèse nulle (H_0) : les résidus ne sont pas autocorrélés (bruit blanc).
- Une p-value > 0.05 indique que l'on ne rejette pas H_0 , donc les résidus sont compatibles avec un bruit blanc.

Le test a été réalisé avec la fonction `Box.test()` dans R ou via `checkresiduals()` du package `forecast` (Hyndman et Athanasopoulos, 2021).

3.5.2. Test ARCH (volatilité conditionnelle)

Le test ARCH (Engle, 1982) a été utilisé pour détecter une hétéroscédasticité conditionnelle dans les résidus. Une présence de volatilité dans les erreurs indiquerait que le modèle sous-

estime ou surestime la variabilité à certains moments, ce qui justifierait l'utilisation d'un modèle GARCH.

- Hypothèse nulle (H_0) : absence d'effets ARCH (variance constante).
- Une p-value > 0.05 signifie que l'on ne détecte pas de volatilité conditionnelle.

Ce test a été mené à l'aide de la fonction `ArchTest()` du package `FinTS`.

3.5.3. Validation visuelle et statistique

Les résidus ont également été inspectés visuellement :

- Histogrammes pour évaluer la normalité (symétrie, absence de queue lourde),
- ACF/PACF des résidus et des résidus au carré pour détecter des structures non capturées,
- Graphiques de résidus standardisés afin de repérer d'éventuelles anomalies, ruptures ou valeurs aberrantes.

Cette combinaison de tests statistiques et de diagnostics graphiques renforce la robustesse de l'évaluation du modèle (Enders, 2015).

3.6. Méthodes complémentaires : GARCH, VaR et Extreme Value Theory

Dans l'analyse des séries temporelles financières ou climatiques à forte variabilité, certains outils permettent d'examiner les phénomènes de volatilité et d'extrêmes. Trois approches sont particulièrement pertinentes dans ces contextes : les modèles GARCH, la Value-at-Risk (VaR) et la théorie des valeurs extrêmes (Extreme Value Theory, EVT). Toutefois, leur application dépend de la nature statistique des séries.

3.6.1. Modèle GARCH

Le modèle GARCH (Generalized Autoregressive Conditional Heteroskedasticity) a été développé par Bollerslev (1986) pour capturer une volatilité conditionnelle, c'est-à-dire des variations non constantes dans la variance des résidus. Il est souvent utilisé lorsque les résidus d'un modèle ARIMA présentent des effets ARCH.

Un modèle GARCH(p, q) s'écrit :

$$\begin{cases} y_t = \mu + \varepsilon_t \\ \varepsilon_t = \sigma_t z_t \\ \sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \end{cases}$$

Où $z_t \sim N(0,1)$ représente un bruit blanc.

Ce modèle est pertinent lorsque le test ARCH est significatif ($p < 0.05$), ce qui indique une volatilité conditionnelle. En l'absence de tels effets, un modèle ARIMA suffit à modéliser la série (Tsay, 2010 ; Enders, 2015).

3.6.2. Value-at-Risk (VaR)

La Value-at-Risk est une mesure statistique largement utilisée en finance pour estimer le risque de perte maximale potentielle à un certain niveau de confiance (ex. : 95 %) sur un horizon donné (Jorion, 2006). Appliquée aux séries climatiques, elle permet d'estimer la probabilité qu'un indicateur (comme la température ou la concentration de CH₄) dépasse un seuil critique.

- La VaR est particulièrement adaptée aux séries présentant une forte variabilité ou des chocs violents.
- En revanche, si les séries sont stables et ne présentent pas de volatilité conditionnelle, la VaR n'apporte que peu d'informations utiles.

3.6.3. Extreme Value Theory (EVT)

La théorie des valeurs extrêmes permet de modéliser les comportements rares et extrêmes observés dans une série, tels que des pics de température ou des concentrations anormalement élevées de gaz. Deux approches principales existent (Coles, 2001) :

- Approche des maxima par blocs (modèle Gumbel, Fréchet, Weibull)
- Approche des excès de seuil (modèle GPD – Generalized Pareto Distribution)

L'EVT est utile lorsque :

- La série présente des extrêmes visibles (queues épaisses, pics soudains),
- Il existe un intérêt pratique à estimer les seuils dépassés.

Elle est peu informative si les séries sont lisses, sans valeur aberrante ni extrême manifeste.

3.7. Analyse de la cointégration

3.7.1. Justification de la cointégration

La cointégration examine l'existence d'une relation de long terme stable entre plusieurs séries non stationnaires intégrées d'ordre 1 (I(1)). Deux séries sont dites cointégrées si une combinaison linéaire de celles-ci est stationnaire, révélant un équilibre structurel sous-jacent (Engle et Granger, 1987). Ici, la cointégration a été testée entre l'anomalie de température, le CO₂ et le CH₄, toutes I(1). Le N₂O, étant I(2), a été exclu afin de respecter les hypothèses des tests ARDL (Pesaran et al., 2001).

3.7.2. Test de cointégration par l'approche ARDL - Bounds Testing

L'approche retenue pour évaluer la cointégration est celle proposée par Pesaran et al. (2001) à travers la méthode ARDL (Autoregressive Distributed Lag), adaptée aux séries de différents ordres d'intégration (I(0) ou I(1)).

Le test de cointégration repose sur le calcul de la statistique F issue de la régression ARDL, que l'on compare à des valeurs critiques tabulées :

- Si $F >$ borne supérieure \rightarrow cointégration confirmée.
- Si $F <$ borne inférieure \rightarrow absence de cointégration.
- Si F entre les deux bornes \rightarrow résultat non concluant.

L'estimation a été réalisée dans R avec le package ARDL, via la fonction `auto_ardl()` pour sélectionner automatiquement les meilleurs retards selon le critère AIC.

3.7.3. Modèle ARDL

Un modèle ARDL a été estimé avec l'anomalie de température comme variable dépendante et les concentrations de CO₂ et de CH₄ comme variables explicatives. Le meilleur modèle a été sélectionné automatiquement avec `auto_ardl` en fixant un `max_order = 3`. Le test de cointégration de Pesaran (Bounds F-Test) a été utilisé pour identifier une relation de long terme entre les variables si $p\text{-value} < 0,01$ (Pesaran et al., 2001).

3.8. Validation des modèles et prévisions

Afin d'évaluer la capacité prédictive des modèles ARIMA, chaque série temporelle a été divisée en deux sous-périodes : un échantillon d'apprentissage (training set), utilisé pour l'estimation du modèle, et un échantillon de validation (test set), réservé à l'évaluation des performances de prévision. Cette approche permet d'évaluer la robustesse hors échantillon de chaque modèle.

Cependant, la longueur des séries disponibles étant variable, la période de segmentation a été adaptée à chaque cas (Tableau 1).

Tableau 1: Données utilisées

Série	Période totale	Période d'apprentissage	Période de test
Température	1880-2024	1880-2015	2016-2024
CO ₂	1974-2024	1974-2018	2019-2024
CH ₄	1984-2023	1984-2015	2016-2023
N ₂ O	2001-2023	2001-2021	2022-2023

Cette segmentation tient compte à la fois de la disponibilité des données et de la nécessité de conserver un volume d'observations suffisant dans l'échantillon d'apprentissage pour garantir la stabilité des estimations. Les performances prédictives des modèles ont ensuite été évaluées sur l'échantillon test à l'aide des indicateurs RMSE, MAE, MAPE, MASE et Theil's U (Hyndman et Athanasopoulos, 2021).

RMSE (Root Mean Squared Error)

Le RMSE mesure l'écart-type des résidus (erreurs de prévision).

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

MAPE (Mean Absolute Percentage Error)

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Le MAPE exprime l'erreur absolue moyenne en pourcentage des valeurs réelles.

MAE (Mean Absolute Error)

Le MAE mesure l'erreur moyenne absolue entre les prédictions et les valeurs observées. Plus le MAE est faible, plus le modèle est précis.

$$\text{MAE} = \text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

Où :

- y_t = valeur réelle (observation à l'instant t)
- \hat{y}_t = valeur prédite à l'instant t
- n = nombre total d'observations

MASE

$$\text{MASE} = \frac{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|}$$

Le numérateur est le MAE du modèle. Le dénominateur est le MAE d'un modèle naïf à un pas en arrière sur le jeu d'entraînement.

MASE < 1 alors le modèle fait mieux que le modèle naïf

MASE \approx 1 alors aussi bon que le naïf

MASE > 1 alors le modèle fait moins bien que le naïf

Theil's U (Theil's U-statistic de type 1) :

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n \left(\frac{F_t - A_t}{A_{t-1}} \right)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n \left(\frac{A_t - A_{t-1}}{A_{t-1}} \right)^2}}$$

où :

- F_t = prévision du modèle
- A_t = valeur réelle observée
- A_{t-1} = valeur observée à l'instant précédent (modèle naïf)

- n = nombre de points dans la période de test

3.9. Limites de l'étude

3.9.1. Limites liées aux données

Une première limite concerne la disponibilité inégale des données selon les variables :

- La température est disponible sur une longue période (1880-2024), tandis que le N₂O n'est couvert que depuis 2001.
- Cela a nécessité une segmentation spécifique pour chaque série (voir section 3.2), ce qui limite les comparaisons croisées directes sur une même période historique.

En outre, le faible nombre d'observations disponibles pour certaines séries (ex. N₂O) réduit la puissance statistique des tests appliqués et limite la fiabilité de certaines prévisions.

3.9.2. Limites liées à la modélisation

Les modèles ARIMA ont été retenus pour leur capacité à modéliser efficacement la dynamique des séries temporelles climatiques. Toutefois, ces modèles sont univariés, ne tenant pas compte d'interactions simultanées entre plusieurs variables dans un même système.

Ils ne permettent pas de capturer les chocs exogènes ou structurels qui peuvent influencer la trajectoire des séries à long terme (ex. politiques climatiques, crises économiques).

Les modèles ARDL ont permis d'introduire une approche multivariée, mais leur validité repose sur l'absence de variables intégrées d'ordre 2, à moins d'utiliser la variable différenciée intégrée d'ordre 1. Les variables CO₂ et N₂O ont dû être différenciées deux fois, ce qui empêche leur utilisation directement pour étudier leurs effets de long terme dans le cadre de ce modèle.

Chapitre 4 : Résultats

Ce chapitre présente les résultats empiriques obtenus à partir de l'analyse des séries temporelles portant sur l'évolution de la température globale et des concentrations de gaz à effet de serre (GES), en particulier le dioxyde de carbone (CO_2), le méthane (CH_4) et le protoxyde d'azote (N_2O). Ces résultats ont été obtenus à travers l'application de différents modèles statistiques, notamment les modèles ARIMA pour la modélisation univariée, et le modèle ARDL pour la mise en évidence des relations de long terme entre les variables.

L'objectif principal est d'identifier les dynamiques individuelles de chaque série, d'évaluer la stationnarité, de modéliser leur comportement et de tester l'existence d'une relation structurelle entre les émissions de GES et la température. Une attention particulière est portée à la qualité des ajustements, à la performance des prévisions sur des données hors échantillon, ainsi qu'à la validité statistique des modèles estimés.

Ce chapitre est structuré en cinq sous sections. La section 4.1 présente une analyse descriptive des séries étudiées, suivie de la section 4.2 qui présente les résultats des tests de stationnarité. Les modèles ARIMA sont exposés en 4.3, tandis que les résultats du modèle ARDL et du test de cointégration sont analysés en 4.4. La section 4.5 justifie l'exclusion des modèles GARCH, de la VaR et des approches par valeurs extrêmes.

4.1. Résultats d'analyse descriptive des séries

Cette section présente une analyse descriptive des séries temporelles étudiées : la température globale annuelle, les concentrations de dioxyde de carbone (CO_2), de méthane (CH_4) et de protoxyde d'azote (N_2O). Ces variables, mesurées sur différentes périodes, permettent de saisir les tendances générales et d'identifier les dynamiques historiques avant toute modélisation.

4.1.1. Évolution de la température globale

La Figure 1 présente l'évolution de l'anomalie de la température moyenne annuelle mondiale, calculée par rapport à la période de référence 1951-1980, conformément à la méthode adoptée par la NASA GISTEMP. Cette anomalie met en évidence une tendance haussière marquée depuis les années 1970, avec une accélération notable du réchauffement à partir des années 1980. Les dernières années affichent des pics dépassant $+1,2$ °C par rapport à la moyenne de 1951-1980.

Il est important de noter que les évaluations du GIEC (Groupe d'experts intergouvernemental sur l'évolution du climat) se réfèrent généralement à une autre période de référence, 1850-1900, correspondant à l'ère préindustrielle (IPCC, 2018). Or, la période 1951-1980 était déjà environ +0,3 à +0,4 °C plus chaude que la période préindustrielle. Par conséquent, une anomalie de +1,2 °C sur le graphique correspond en réalité à un réchauffement d'environ +1,5 à +1,6 °C par rapport à l'ère préindustrielle.

Cette tendance confirme les conclusions des rapports successifs du GIEC, qui soulignent une hausse actuelle de la température globale d'environ +1,1 °C depuis l'ère préindustrielle, et alertent sur le dépassement imminent du seuil critique de +1,5 °C si les émissions de gaz à effet de serre ne sont pas drastiquement réduites.




Figure 1 : : Evolution des anomalies de température annuelle globale

4.1.2. Tendances des concentrations de CO₂

La concentration atmosphérique de dioxyde de carbone (CO₂) présente une croissance régulière et soutenue sur la période 1974–2024. Elle est passée d'environ 330 parties par million (ppm) au milieu des années 1970 à plus de 420 ppm en 2024, soit une augmentation de plus de 90 ppm en un demi-siècle. Cette tendance reflète principalement l'effet cumulatif des activités

humaines intensives : combustion d'énergies fossiles (charbon, pétrole, gaz naturel), déforestation, industrialisation rapide, et agriculture intensive.




Figure 2: : Evolution annuelle des concentrations de CO2

Le CO₂ étant le principal gaz à effet de serre d'origine anthropique, sa concentration croissante dans l'atmosphère constitue l'un des moteurs majeurs du réchauffement climatique mondial. Il existe une forte corrélation entre évolution de concentration de CO₂ et évolution des anomalies de température (Figure 3). Cette corrélation est de 0,96 (Tableau 1). Cette évolution est en cohérence avec les alertes du GIEC, qui identifie une forte corrélation entre la hausse des émissions de CO₂ et l'élévation des températures moyennes à l'échelle planétaire.




Figure 3 : Evolution annuelle croisée des concentrations de CO₂ et anomalie de température moyenne mondiale

4.1.3. Tendances des concentrations de CH₄

La concentration atmosphérique de méthane (CH₄) suit une trajectoire globalement ascendante sur la période 1984–2023 (Figure 4). Après une stabilisation relative entre les années 2000 et 2007, la courbe montre une reprise nette et accélérée de la croissance du CH₄, particulièrement marquée à partir de la fin des années 2000.

Bien que mesurée en parties par milliard (ppb) et donc numériquement inférieure à celle du CO₂, la concentration de méthane reste préoccupante en raison de son potentiel de réchauffement global (PRG) environ 80 à 86 fois plus élevé que celui du CO₂ sur un horizon de 20 ans (IPCC, 2021). Cette hausse est liée à des sources anthropiques telles que l’agriculture (riziculture, fermentation entérique), les décharges, et l’exploitation des hydrocarbures (gaz naturel et pétrole), ainsi qu’à des rétroactions naturelles (zones humides, fonte du pergélisol).




Figure 4: : Evolution des concentrations de méthane (CH₄)

4.1.4. Tendances des concentrations de N₂O

Le protoxyde d'azote (N₂O), troisième principal gaz à effet de serre d'origine anthropique, présente une croissance constante et linéaire sur la période 2001–2023 (Figure 5). Sa concentration atmosphérique est passée de près de 316 ppb à plus de 330 ppb, marquant une augmentation régulière d'environ 0,8 à 1,0 ppb par an.

Cette évolution est principalement attribuée à l'utilisation massive d'engrais azotés dans l'agriculture, qui constitue la première source d'émissions anthropiques de N₂O. Ce gaz possède un potentiel de réchauffement global (PRG) environ 273 fois supérieur à celui du CO₂ sur un horizon de 100 ans, selon les estimations du GIEC (IPCC, 2021). En outre, il contribue à la destruction de la couche d'ozone stratosphérique, ce qui en fait un polluant doublement problématique sur les plans climatique et environnemental.

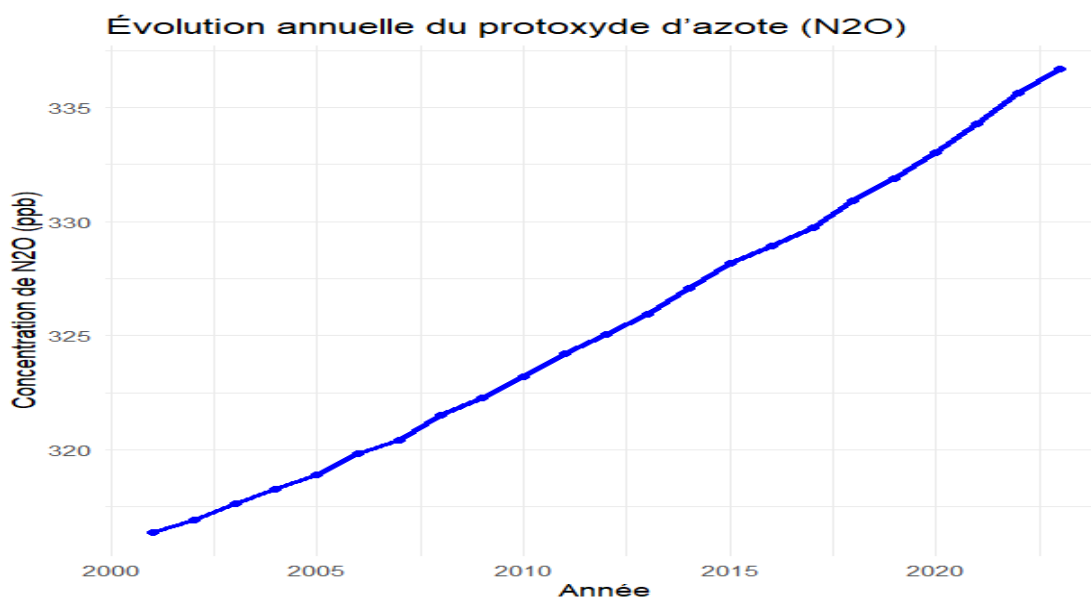


Figure 5: : Evolution des concentrations de protoxyde d'azote (N₂O)

4.1.5. Corrélations entre les séries

Une matrice de corrélation a été calculée entre les séries synchronisées sur la période commune (2001–2023) pour explorer les associations linéaires (Tableau 2). Ces corrélations suggèrent des liens statistiques forts entre la température et les GES, en particulier le CO₂, ce qui justifie l'estimation de modèles multivariés tels que l'ARDL.

Tableau 2: Matrice de Corrélation

Variables	Température	CO ₂	CH ₄	N ₂ O
Température	1,00	0,91	0,89	0,83
CO ₂	0,91	1,00	0,96	0,94
CH ₄	0,89	0,96	1,00	0,92
N ₂ O	0,83	0,94	0,92	1,00

4.2. Résultats des tests de stationnarité

Les tests de stationnarité constituent une étape préalable essentielle à toute modélisation des séries temporelles. Une série non stationnaire présente des propriétés statistiques variables dans le temps (moyenne, variance, autocorrélation), ce qui peut fausser les estimations. La stationnarité est donc une condition nécessaire pour garantir la validité des modèles ARIMA et ARDL.

Le test de stationnarité utilisé dans cette étude est le test de Dickey-Fuller augmenté (ADF). Il permet de détecter la présence d'une racine unitaire, indicatrice d'une série non stationnaire.

- Hypothèse nulle (H_0) : la série possède une racine unitaire (non stationnaire).
- Hypothèse alternative (H_1) : la série est stationnaire.

Une p-value inférieure à 0,05 conduit au rejet de H_0 , indiquant une stationnarité de la série. Les tests ont été appliqués aux séries en niveau et, si nécessaire, après une ou deux différenciations.

Les résultats du test ADF appliqué aux quatre séries sont présentés dans le tableau 3 ci-dessous.

Tableau 3: Résultats du test ADF

Série	Niveau	1ere différenciation	2eme différenciation	Ordre d'intégration
Température	Non stationnaire (p > 0.1)	Stationnaire (p < 0.01)	–	I(1)
CO ₂	Non stationnaire (p > 0.1)	Non stationnaire (p > 0.1)	Stationnaire (p < 0.05)	I(2)
CH ₄	Non stationnaire (p > 0.1)	Non stationnaire (p > 0.1)	Stationnaire (p < 0.05)	I(2)
N ₂ O	Non stationnaire (p > 0.1)	Non stationnaire (p > 0.1)	Stationnaire (p < 0.05)	I(2)

- L'anomalie de température et le CH₄ sont intégrés d'ordre 1 (I(1)), ce qui le rend éligibles pour une modélisation ARIMA(p,1,q) et pour inclusion dans un modèle ARDL.
- Le CO₂ et le N₂O sont intégrés d'ordre 2 (I(2)). Ces séries ont été différenciées deux fois pour être rendues stationnaires. Toutefois, les séries I(2) ne peuvent pas être incluses dans un modèle ARDL non modifié, ce qui justifie leur exclusion (en niveau) de l'analyse de cointégration. Pour les inclure, il faut utiliser ces séries différenciées.
- La série CH₄ est intégrée d'ordre 2 (I(2)), mais la fraction de la série utilisée dans le modèle ARDL est intégrée d'ordre 1 (I(1)).

4.3. Résultats de l'estimation des modèles ARIMA

Les modèles ARIMA ont été appliqués pour modéliser et prévoir l'évolution individuelle de chaque série temporelle stationnarisée. Cette approche univariée permet de capturer les dynamiques internes de chaque variable, indépendamment des autres facteurs.

4.3.1. Température globale

Le modèle sélectionné pour la température est un ARIMA(1,1,3), avec une différenciation d'ordre 1.

- **Forme du modèle :**

$$\Delta Temp_t = c + \phi_1 \Delta Temp_{t-1} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \theta_3 \varepsilon_{t-3} + \varepsilon_t$$

Le tableau 4 montre que les coefficients estimés sont statistiquement significatifs ($p < 0,05$).

Tableau 4 : Estimation du modèle ARIMA (1,1,3) des anomalies de températures

Coefficient	Estimate	Std. Error	z value	p-value	Significatif
AR1	-0.9437	0.0545	-17.31	< 2.2e-16	*** (très fort)
MA1	0.6150	0.0963	6.39	1.71e-10	***
MA2	-0.5773	0.0821	-7.04	1.99e-12	***
MA3	-0.3247	0.0811	-4.01	6.12e-05	***
Drift	0.0072	0.0030	2.25	0.0242	* (significatif à 5%)

Le modèle s'écrit :

$$\Delta Temp_t = 0.007 - 0.943 \Delta Temp_{t-1} + 0.615 \varepsilon_{t-1} - 0.577 \varepsilon_{t-2} - 0.325 \varepsilon_{t-3} + \varepsilon_t$$

- **Résidus non autocorrélés (test de Ljung-Box : $p > 0,1$)**

Il s'agit de vérifier si les résidus sont autocorrélés, c'est-à-dire, s'il reste une structure dans les résidus après l'ajustement du modèle ARIMA. L'hypothèse nulle est :

H_0 : Il n'y a pas d'autocorrélation significative dans les résidus

Le test de Ljung-Box appliqué aux résidus du modèle ARIMA(1,1,3) avec drift à l'aide de la fonction `checkresiduals()` dans R donne les résultats :

$$Q^* = 4.5934 : \text{statistique du test ; } df = 5 : \text{degrés de liberté ; } p\text{-value} = 0.4675$$

Cela signifie que les résidus ne présentent pas d'autocorrélation significative, donc le modèle ARIMA(1,1,3) semble correctement spécifié du point de vue des dépendances temporelles.

Le modèle ARIMA(1,1,3) avec drift est adéquat : il a capté l'essentiel de la structure de la série temporelle, et ses résidus peuvent être considérés comme du bruit blanc (indépendants dans le temps).

- Pas d'hétéroscédasticité conditionnelle (test ARCH)

Le test ARCH LM (Lagrange Multiplier) appliqué aux résidus du modèle ARIMA(1,1,3), avec lags = 5. Ce test est réalisé via la fonction ArchTest() du package FinTS.

L'objectif est de tester la présence d'hétéroscédasticité conditionnelle (effets ARCH) dans les résidus.

H_0 : Pas d'effet ARCH (les variances conditionnelles sont constantes dans le temps).

Statistique $\chi^2 = 6.0641$; ddl = 5, p-value = 0.3

p-value = 0.3 > 0.05 : on ne rejette pas l'hypothèse nulle.

Cela signifie qu'il n'y a pas d'effet ARCH significatif dans les résidus.

En d'autres termes, la variance des résidus est stable dans le temps. On n'a pas besoin de modéliser avec GARCH.

Les résidus du modèle ARIMA (1,1,3) ne présentent pas d'hétéroscédasticité conditionnelle détectable. Cela renforce la validité du modèle : les hypothèses classiques (bruit blanc, variance constante) sont respectées.

Test de normalité des résidus

Le test de Jarque-Bera appliqué aux résidus du modèle ARIMA (1,1,3) donne : Statistique de test (X-squared) : 3.277 ; Degrés de liberté (df) : 2 ; p-value : 0.1943

La p-value = 0.1943 > 0.05 \Rightarrow on ne peut pas rejeter H_0 .

Les résidus sont donc compatibles avec une distribution normale (au seuil de 5 %). Cela valide l'hypothèse de normalité, ce qui est favorable pour les inférences statistiques (prévisions, intervalles de confiance, tests).

Les Figures 6 et 7 confirment la normalité des résidus.




Figure 6: : Résidus du modèle ARIMA (1, 1, 3) pour les anomalies de température




Figure 7: : QQ-Plot sur les résidus du modèle ARIMA (1,1,3)

Prédictions stables sur la période test (2016–2024)

La figure 8 présente graphiquement des prédictions du modèle :

$$\Delta Temp_t = 0.007 - 0.943 \Delta Temp_{t-1} + 0.615 \varepsilon_{t-1} - 0,577 \varepsilon_{t-2} - 0.325 \varepsilon_{t-3} + \varepsilon_t .$$

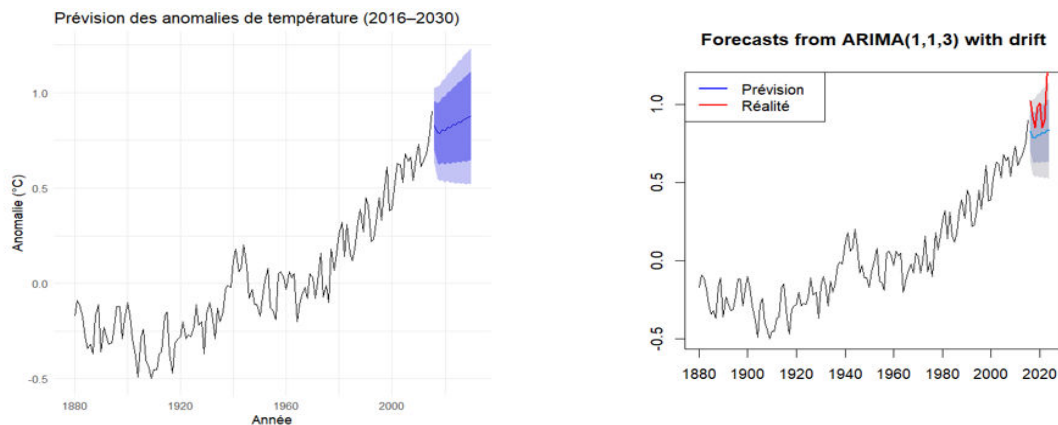


Figure 8: : Prédiction du modèle ARIMA (1,1,3)

L'évaluation de la qualité des prévisions du modèle ARIMA s'appuie sur trois indicateurs standards d'erreur :

- MAE (Mean Absolute Error) : 0.1883
- RMSE (Root Mean Squared Error): 0.2292
- MAPE (Mean Absolute Percentage Error) : 0.1748

Ces trois mesures indiquent une bonne performance prédictive du modèle.

Le MAE indique que, en moyenne, les prévisions s'écartent de 0.188 unités des valeurs réellement observées. C'est une erreur absolue modérée, qui ne pénalise pas les grandes erreurs plus que les petites.

Le RMSE, légèrement plus élevé que le MAE (0.229), intègre la variance des erreurs. Sa valeur proche de celle du MAE suggère qu'il n'existe pas de grandes erreurs isolées : les erreurs sont relativement homogènes.

Le MAPE, à 17.48 %, montre que les erreurs représentent en moyenne moins de 18 % des valeurs observées.

4.3.2. CO₂

Pour le dioxyde de carbone, un ARIMA (2,2,3) a été retenu, la série nécessitant deux différenciations pour atteindre la stationnarité.

$$\Delta^2 CO_{2,t} = \phi_1 \Delta^2 CO_{2,t-1} + \phi_2 \Delta^2 CO_{2,t-2} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \theta_3 \varepsilon_{t-3} + \varepsilon_t$$

Le tableau 5 montre que tous les coefficients sont statistiquement significatifs au seuil de 5 %, y compris MA(1) (p = 0.0307). Les coefficients AR(1) et AR(2) sont hautement significatifs (p < 0.001), ce qui confirme une forte mémoire dans les double-différences de la série CO₂. Les trois coefficients MA sont significatifs, indiquant que la moyenne mobile d'ordre 3 est justifiée.

Tableau 5 : Résultats d'estimation du modèle ARIMA (2,2,3)

Coefficient	Estimate	Std. Error	z value	p-value	Signif
AR1	-0.3682	0.0343	-10.74	< 2.2e-16	***
AR2	-0.9956	0.0141	-70.80	< 2.2e-16	***
MA1	-0.2983	0.1380	-2.16	0.0307	*
MA2	0.6832	0.1289	5.30	1.17e-07	***
MA3	-0.7314	0.1381	-5.30	1.18e-07	***

Le modèle s'écrit :

$$\Delta^2 CO_{2,t} = -0.368 \cdot \Delta^2 CO_{2,t-1} - 0.996 \cdot \Delta^2 CO_{2,t-2} - 0.299 \cdot \varepsilon_{t-1} + 0.683 \cdot \varepsilon_{t-2} - 0.731 \cdot \varepsilon_{t-3} + \varepsilon_t$$

- **Résidus non autocorrélés (test de Ljung-Box : p > 0,1)**

Le résultat du test de Ljung-Box sur les résidus du modèle ARIMA (2,2,3) donne Statistique Q* = 5.655 ; Degrés de liberté = 4 ; p-value = 0.2264

- H₀ : les résidus sont non autocorrélés (i.e. bruit blanc)
- p-value = 0.2264 > 0.05 ⇒ on ne rejette pas H₀

Les résidus du modèle ARIMA (2,2,3) ne présentent pas d'autocorrélation significative. Le modèle est bien spécifié du point de vue des dépendances temporelles.

- **Pas d'hétéroscédasticité conditionnelle (test ARCH)**

Le test ARCH LM sur les résidus du modèle ARIMA (2,2,3) pour la série CO₂ donne les résultats : Statistique Chi² : 1.9561 ; Degrés de liberté (df) : 5 ; p-value = 0.8552

- H_0 : il n'y a pas d'effet ARCH (pas d'hétéroscédasticité conditionnelle).
- $p\text{-value} = 0.8552 > 0.05$; on ne rejette pas H_0

Les résidus du modèle ARIMA (2,2,3) ne présentent pas d'hétéroscédasticité conditionnelle. Autrement dit, la variance est stable dans le temps, ce qui renforce la validité du modèle et montre qu'il n'est pas nécessaire de modéliser avec GARCH.

Test de normalité des résidus

Le test de Jarque-Bera pour la normalité des résidus donne des résultats suivants :

Statistique $X^2 = 1.8691$; $df = 2$; $p\text{-value} = 0.3928$

- H_0 : les résidus suivent une loi normale.
- $p\text{-value} = 0.3928 > 0.05 \Rightarrow$ on ne rejette pas H_0

Les résidus du modèle ARIMA (2,2,3) sont compatibles avec une distribution normale. Cela respecte l'une des hypothèses fondamentales des modèles ARIMA et garantit la validité des inférences statistiques (intervalles de confiance, prévisions) (Figures 9 et 10).

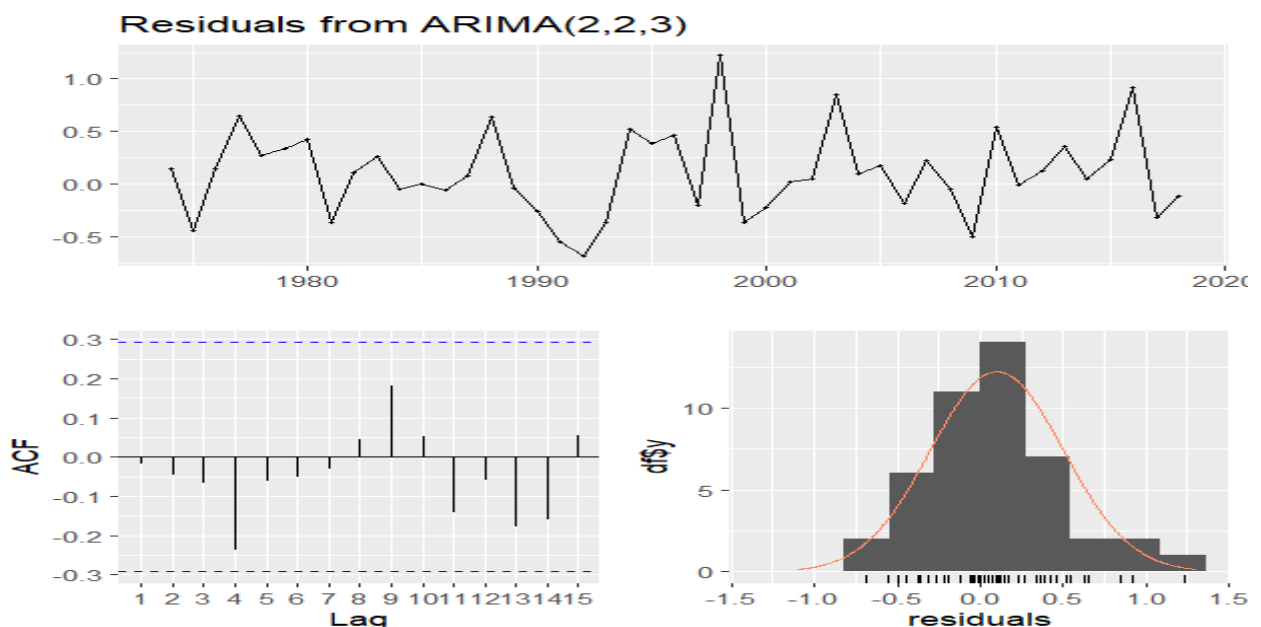


Figure 9: : Résidus du modèle ARIMA (2, 2, 3) pour le CO2




Figure 10: : QQ-Plot sur les résidus du modèle ARIMA (2,2,3)

Prédictions stables sur la période test (2019–2024)

La figure 11 présente graphiquement des prédictions du modèle :

$$\Delta^2 CO_{2,t} = -0.368 \cdot \Delta^2 CO_{2,t-1} - 0.996 \cdot \Delta^2 CO_{2,t-2} - 0.299 \cdot \varepsilon_{t-1} + 0.683 \cdot \varepsilon_{t-2} - 0.731 \cdot \varepsilon_{t-3} + \varepsilon_t$$

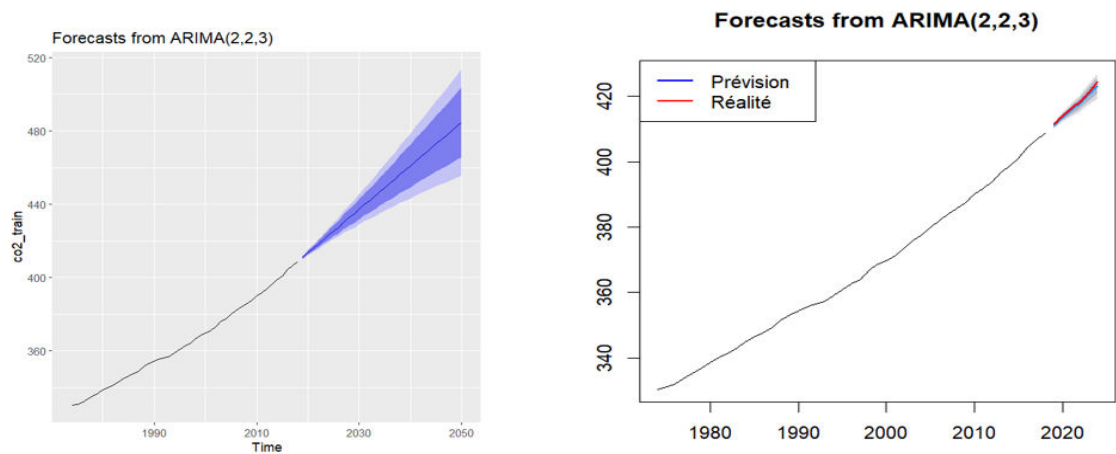


Figure 11: : Prédiction du modèle ARIMA (2,2,3)

L'évaluation de la qualité des prévisions du modèle ARIMA s'appuie sur trois indicateurs standards d'erreur :

- MAE (Mean Absolute Error) : 0.5931 (Erreur absolue moyenne : écart modéré)
- RMSE (Root Mean Squared Error): 0.6796 (Erreur quadratique moyenne : stable)
- MAPE (Mean Absolute Percentage Error) : 0.14 % (Erreur relative extrêmement faible)

Ces trois mesures indiquent une bonne performance prédictive du modèle.

- Le MAE montre que les prévisions s'écartent en moyenne de 0.593 unité(s) de la valeur réelle, ce qui est faible compte tenu de l'échelle des données CO₂.
- Le RMSE, proche du MAE, confirme l'absence d'erreurs extrêmes et une erreur homogène.
- Le MAPE est exceptionnellement bas (0.14 %) : cela signifie que les prévisions sont extrêmement précises en proportion des valeurs observées.

Le modèle affiche une excellente performance prédictive sur la période de test (2019-2024), avec des erreurs faibles en valeur absolue (MAE, RMSE) et quasiment négligeables en proportion (MAPE < 1%).

Cela confirme que le modèle ARIMA(2,2,3) est non seulement statistiquement valide, mais également opérationnellement performant pour la prévision de la concentration en CO₂.

4.3.3. CH₄

Le modèle estimé pour le méthane est un ARIMA (2,2,0).

$$\Delta^2 CH_{4,t} = \phi_1 \cdot \Delta^2 CH_{4,t-1} + \phi_2 \cdot \Delta^2 CH_{4,t-2} + \varepsilon_t$$

Pour le méthane, un ARIMA (2,2,0) a été retenu, la série nécessitant deux différenciations pour atteindre la stationnarité.

$$\Delta^2 CH_{4,t} = -0.1013 \cdot \Delta^2 CH_{4,t-1} - 0.4906 \cdot \Delta^2 CH_{4,t-2} + \varepsilon_t$$

- Le terme AR(2) est hautement significatif, ce qui justifie sa présence dans le modèle (Tableau 6).

- Le terme AR(1) n'est pas statistiquement significatif ($p > 0.05$), mais sa présence n'altère pas la qualité globale du modèle (AIC minimal, résidus valides)

Même si l'un des coefficients n'est pas significatif, l'ensemble du modèle reste statistiquement valide, bien spécifié, et performant en prévision. La structure ARIMA (2,2,0) est conservée pour garantir la cohérence du modèle avec les critères d'information (AIC) et les diagnostics des résidus.

Tableau 6 : Résultats d'estimation du modèle ARIMA (2,2,0)

Coefficient	Estimate	Std. Error	z value	p-value	Signif
AR1	-0.1013	0.1488	-0.681	0.496	Non significatif
AR2	-0.4906	0.1440	-3.407	0.000656	***

Le modèle s'écrit :

$$\Delta^2 CH_{4,t} = -0.1013 \cdot \Delta^2 CH_{4,t-1} - 0.4906 \cdot \Delta^2 CH_{4,t-2} + \varepsilon_t$$

- Résidus non autocorrélés (test de Ljung-Box : $p > 0,1$)

Le résultat du test de Ljung-Box sur les résidus du modèle ARIMA (2,2,0) donne Statistique $Q^* = 0.68474$; Degrés de liberté = 5 ; p-value = 0.9838

- H_0 : les résidus sont non autocorrélés (i.e. bruit blanc)
- p-value = 0.9838 > 0.05 \Rightarrow on ne rejette pas H_0

Les résidus du modèle ARIMA (2,2,0) ne présentent aucune autocorrélation significative. Cela confirme que le modèle a correctement capturé la dynamique temporelle de la série CH_4 .

- Pas d'hétéroscédasticité conditionnelle (test ARCH)

Le test ARCH LM sur les résidus du modèle ARIMA (2,2,0) pour la série CH_4 donne les résultats : $\chi^2 = 2.3429$; Degrés de liberté (df) : 5 ; p-value = 0.7999

- H_0 : il n'y a pas d'effet ARCH (pas d'hétéroscédasticité conditionnelle).
- p-value = 0.7999 > 0.05 ; on ne rejette pas H_0

Il n'y a aucune hétéroscédasticité conditionnelle détectée dans les résidus. Cela signifie que la variance des erreurs est stable, ce qui valide l'utilisation du modèle ARIMA sans extension GARCH.

Test de normalité des résidus

Le test de Jarque-Bera pour la normalité des résidus donne des résultats suivants :

- $X^2 = 4.3204$; Degrés de liberté = 2 ; p-value = 0.1153
- H_0 : les résidus suivent une loi normale.
- p-value = 0.3928 > 0.05 \Rightarrow on ne rejette pas H_0

Les résidus du modèle ARIMA (2,2,0) pour la série CH₄ sont compatibles avec une distribution normale au seuil de 5 % (Figure 12).

Cela renforce la validité statistique du modèle et autorise l'utilisation des prévisions, intervalles de confiance, et tests classiques.

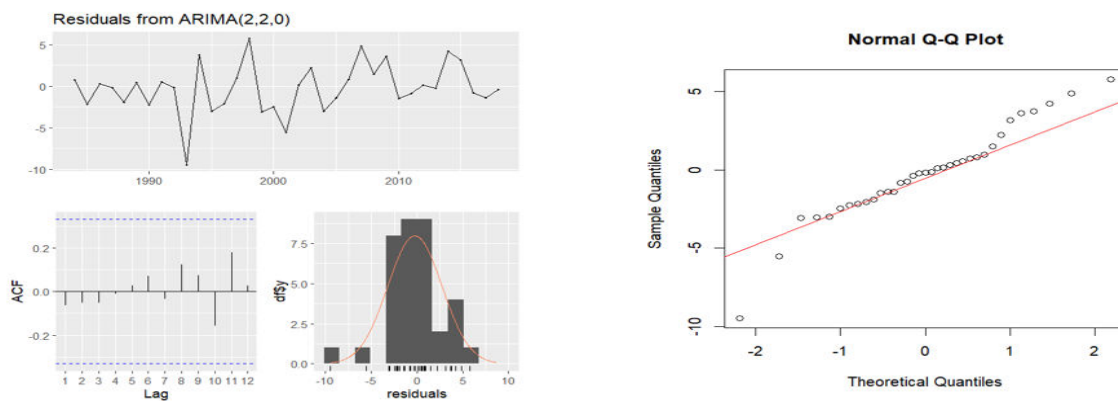


Figure 12: : Résidus du modèle ARIMA (2, 2, 0) et QQ-Plot pour le CH₄

Prédictions de concentrations de CH₄ sur la période test (2019–2023) et jusqu'à 2030

La figure 13 présente graphiquement des prédictions du modèle :

$$\Delta^2 CH_{4,t} = -0.1013 \cdot \Delta^2 CH_{4,t-1} - 0.4906 \cdot \Delta^2 CH_{4,t-2} + \varepsilon_t$$

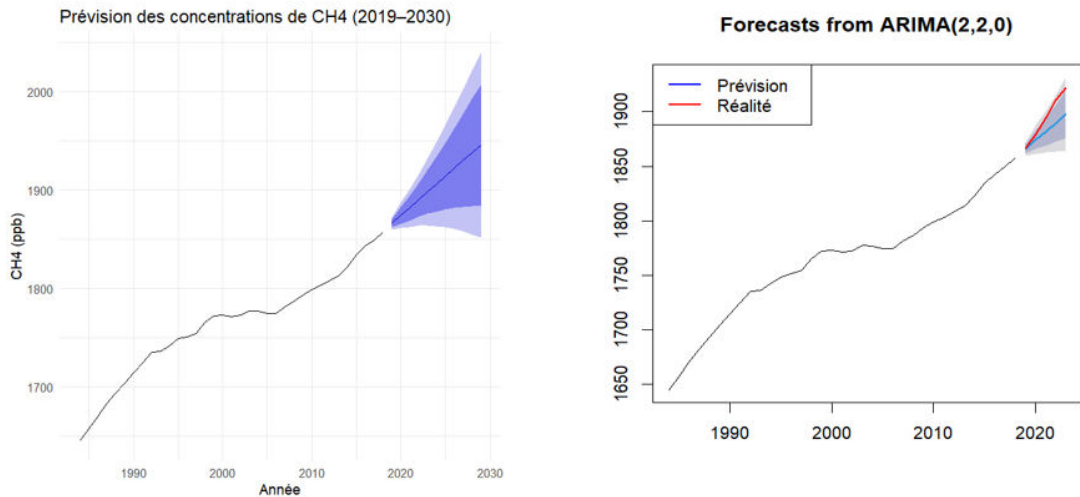


Figure 13: : Prédiction du modèle ARIMA (2,2,0)

L'évaluation de la qualité des prévisions du modèle ARIMA s'appuie sur trois indicateurs standards d'erreur :

- MAE (Mean Absolute Error) : 12.56
- RMSE (Root Mean Squared Error): 15.48
- MAPE (Mean Absolute Percentage Error) : 0.658 % (Très bonne précision relative)

Ces trois mesures indiquent une bonne performance prédictive du modèle.

- Le MAE indique un écart moyen de 12.56 unités entre les valeurs prévues et observées.
- Le RMSE, légèrement plus élevé, montre que les erreurs sont globalement cohérentes et sans valeur aberrante majeure.
- Le MAPE de 0.658 % (soit moins de 1 % d'erreur relative) est exceptionnellement bas, ce qui indique une très bonne précision.

Cela confirme que le modèle ARIMA(2,2,0) est non seulement statistiquement valide, mais également opérationnellement performant pour la prévision de la concentration en CH4.

4.3.4. N₂O

Le protoxyde d'azote a été modélisé par un ARIMA(0,2,1).

Forme du modèle :

$$\Delta^2 N_2 O_t = \mu + \theta_1 \varepsilon_{t-1} + \varepsilon_t ; \text{ici } \mu = 0$$

$$\Delta^2 N_2 O_t = \theta_1 \cdot \varepsilon_{t-1} + \varepsilon_t$$

Pour le Protoxyde d'azote (oxyde nitreux), un ARIMA (0,2,1) a été retenu, la série nécessitant deux différenciations pour atteindre la stationnarité.

$$\Delta^2 N_2 O_t = -0.6528 \cdot \varepsilon_{t-1} + \varepsilon_t$$

Le tableau 7 montre que le coefficient de MA(1) est statistiquement significatif au seuil de 5 %. Cela indique que le terme de moyenne mobile d'ordre 1 est essentiel dans la dynamique de la série N₂O après double différenciation.

Tableau 7 : Résultats d'estimation du modèle ARIMA (0,2,1)

Coefficient	Estimate	Std. Error	z value	p-value	Signif
MA(1)	-0.65276	0.14983	-4.3568	1.32e-05	***

Le modèle s'écrit :

$$\Delta^2 N_2 O_t = -0.6528 \cdot \varepsilon_{t-1} + \varepsilon_t$$

- Résidus non autocorrélés (test de Ljung-Box : p > 0,1)

Le résultat du test de Ljung-Box sur les résidus du modèle ARIMA (0,2,1) donne Statistique Q* = 2.883 ; Degrés de liberté = 3 ; p-value = 0.41

- H₀ : les résidus sont non autocorrélés (i.e. bruit blanc)
- p-value = 0.41 > 0.05 ⇒ on ne rejette pas H₀

Les résidus du modèle ARIMA (0,2,1) ne présentent pas d'autocorrélation significative. Les résidus de la série N₂O sont un bruit blanc.

- Pas d'hétéroscédasticité conditionnelle (test ARCH)

Le test ARCH LM sur les résidus du modèle ARIMA (0,2,1) pour la série N₂O donne les résultats : Statistique Chi² : 6.3246 ; Degrés de liberté (df) : 5 ; p-value = 0.2759

- H₀ : absence d'effet ARCH (variance constante des résidus).
- p-value = 0.2759 > 0.05 ; on ne rejette pas H₀

Les résidus du modèle ARIMA (0,2,1) ne présentent aucune hétéroscédasticité conditionnelle détectable. Cela confirme que la variance est stable dans le temps, et qu'il n'est pas nécessaire de recourir à un modèle GARCH.

- Test de normalité des résidus

Le test de Jarque-Bera pour la normalité des résidus donne des résultats suivants :

Statistique $X^2 = 1.0085$; df = 2 ; p-value = 0.604

- H₀ : les résidus suivent une loi normale.
- p-value = 0.604 > 0.05 ⇒ on ne rejette pas H₀

Les résidus du modèle ARIMA (0,2,1) sont compatibles avec une distribution normale. Cela respecte l'une des hypothèses fondamentales des modèles ARIMA et garantit la validité des inférences statistiques (intervalles de confiance, prévisions) (Figure 14).

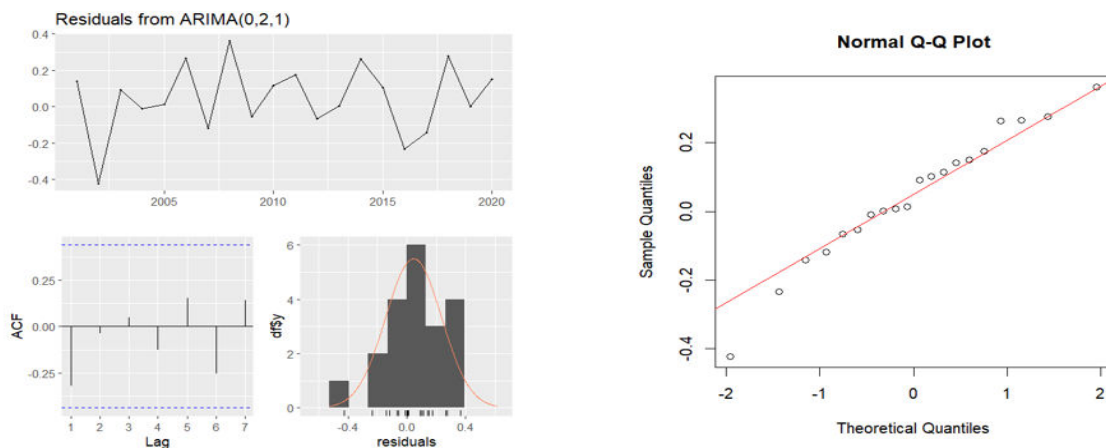


Figure 14: : Résidus et QQ-Plot sur les résidus du modèle ARIMA (0,2,1)

Prédictions stables sur la période test (2021–2024)

La figure 15 présente graphiquement des prédictions du modèle :

$$\Delta^2 N_2 O_t = -0.6528 \cdot \varepsilon_{t-1} + \varepsilon_t$$

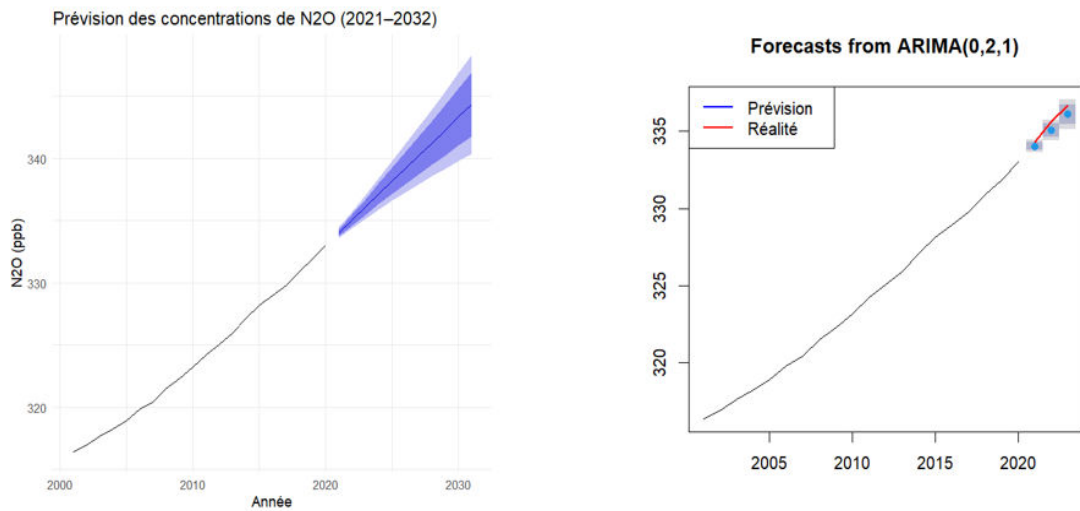


Figure 15: : Prédiction du modèle ARIMA (0,2,1)

L'évaluation de la qualité des prévisions du modèle ARIMA s'appuie sur trois indicateurs standards d'erreur :

- MAE (Mean Absolute Error) : 0.4567 (Erreur absolue moyenne : faible)
- RMSE (Root Mean Squared Error): 0.4823 (Erreur quadratique moyenne: stable)
- MAPE (Mean Absolute Percentage Error) : 0.1359 % (Erreur relative extrêmement faible, haute précision)

Ces trois mesures indiquent une bonne performance prédictive du modèle.

- Le modèle génère des prévisions très proches des observations réelles.
- Le MAPE de 0.1359 % indique que l'erreur moyenne est inférieure à 0.15 % des valeurs observées, ce qui est exceptionnellement bas.
- La proximité entre MAE et RMSE montre que les erreurs sont homogènes, sans valeurs aberrantes.

Le modèle ARIMA (0,2,1) offre une excellente performance de prévision pour la série N₂O, avec une précision quasi-parfaite sur la période de test. Il constitue une base robuste et statistiquement valide pour anticiper l'évolution future du protoxyde d'azote.

4.3.5. Évaluation des résidus

L'ensemble des modèles ARIMA ajustés aux séries climatiques (Température, CO₂, CH₄, N₂O) ont été soumis à des tests rigoureux de diagnostic des résidus, conformément aux bonnes pratiques en analyse de séries temporelles. Les résultats sont les suivants :

- **Absence d'autocorrélation résiduelle :**

Les tests de Ljung-Box appliqués à chaque modèle montrent que les résidus sont non autocorrélés (p-values > 0.05), indiquant que les modèles capturent efficacement les dépendances temporelles. Les résidus peuvent ainsi être considérés comme du bruit blanc, ce qui valide la spécification structurelle des ARIMA utilisés.

- **Absence d'hétéroscédasticité conditionnelle :**

Les tests ARCH (LM test) menés sur les résidus n'ont révélé aucune volatilité résiduelle significative (p-values > 0.2 dans tous les cas). Les modèles n'exhibent donc aucun effet ARCH, et la variance des erreurs peut être considérée comme constante dans le temps. Il n'a donc pas été nécessaire de recourir à des modèles GARCH.

- **Normalité des résidus :**

Les tests de Jarque-Bera montrent que les résidus suivent une distribution compatible avec la normalité (p-values > 0.05 pour tous les modèles). Les histogrammes et les QQ-plots appuient visuellement ces conclusions, renforçant la validité des modèles pour l'inférence et la prévision.

En somme, les tests de diagnostic appliqués aux modèles ARIMA indiquent que les résidus ne contiennent pas de structure résiduelle exploitable, ni sous forme de corrélation, ni sous forme de variance instable ou de déviation de la normalité. Cela confirme que les modèles ARIMA sélectionnés capturent correctement la dynamique temporelle des séries climatiques étudiées, et sont donc adéquats pour les prévisions à moyen terme.

4.3.6. Performance de prévision

Les modèles ont été évalués sur leurs performances hors échantillon, à l'aide de plusieurs indicateurs (RMSE, MAE, MAPE, Theil's U) (Tableau 8).

Tableau 8 : Performance de prévision des modèles sur le test

Variables	Période test	RMSE	MAE	MAPE	MASE	Theil's U
Température	2016 – 2024	0.2292 : Faible	0.1883 : Faible	17.48 % : acceptable	2.045	1.5562 : pire que le modèle naïf
CO ₂	2019 – 2024	0.6796 : Très faible	0.5931 : Très faible	0.6581 % : excellent	0.3329	0.2608 : Très bon
CH ₄	2016 – 2023	2.9334 : Modéré	2.1408 : Modéré	12.13 % : acceptable	1.919	1.2280 : pire que le modèle naïf
N ₂ O	2021 – 2023	0.4823 : Faible	0.4567 : Faible	0.136 % : excellent	0.521	0.466 : Très bon

- Le modèle ARIMA pour CO₂ et N₂O montre une excellente précision prédictive, avec des erreurs faibles et MASE et Theil's U largement < 1.
- Le modèle pour la température, bien qu'ayant des erreurs faibles, échoue à battre le modèle naïf.
- Pour CH₄, la performance est moyenne : acceptable en termes d'erreur, mais non compétitive par rapport au modèle naïf.

4.4. Résultats du modèle ARDL

Dans cette section, nous présentons les résultats de l'estimation du modèle ARDL (Autoregressive Distributed Lag Model), qui permet de capturer les dynamiques de court et de long terme entre les variables climatiques étudiées. Ce modèle est particulièrement adapté lorsque les variables explicatives sont intégrées d'ordre différent (I(0) et I(1)), mais pas d'ordre 2 (I(2)). L'objectif principal ici est d'analyser l'impact des concentrations de gaz à effet de serre (CO₂ et CH₄) sur la température globale, tout en tenant compte des décalages temporels.

4.4.1. Présentation du modèle estimé

Le modèle ARDL a été estimé automatiquement via la fonction `auto_ardl()` en sélectionnant les retards optimaux à l'aide du critère d'information AIC.

Sur la base des résultats des critères d'Akaike (AIC), le meilleur modèle retenu, exclue la variable N₂O, intégrée d'ordre 2. Seules les variables température, CO₂ et CH₄ ont été retenues dans le modèle ARDL de l'analyse de cointégration.

Le modèle retenu est de la forme ARDL(1,0,0), où :

- La température est la variable dépendante, avec un retard d'ordre 1
- CO₂ est introduit sans retard,
- CH₄ est inclus sans retard.

$$\text{temp_anomalie}_t = \alpha + \phi_1 \cdot \text{temp_anomalie}_{t-1} + \beta_0 \cdot \text{ch4_ppb}_t + \delta_0 \cdot \text{co2_diff}_t + \varepsilon_t$$

4.4.2. Estimation des coefficients

Le modèle retenu par le critère AIC présente une structure dynamique intégrant un retard de la variable dépendante :

$$\begin{aligned} \text{temp_anomalie}_t = & -4.191 + 0.126 \cdot \text{temp_anomalie}_{t-1} + 0.00249 \cdot \text{ch4_ppb}_t \\ & + 0.149 \cdot \text{co2_diff}_t + \varepsilon_t \end{aligned}$$

Interprétation des coefficients :

- Intercept : La constante est significative ($p < 0.001$), avec une valeur de -4.191. Elle capte la valeur de référence de l'anomalie quand toutes les variables explicatives sont nulles (à relativiser car les données ne sont pas centrées).
- Effet retardé de la température ($\text{temp_anomalie}_{t-1}$) : Le coefficient est positif (0.126), suggérant une inertie thermique, mais non significatif ($p = 0.504$). Cela indique que la température passée n'améliore pas significativement la prévision actuelle dans ce modèle.
- Méthane atmosphérique (CH₄) : Le coefficient est positif et hautement significatif ($p < 0.001$), avec une valeur de 0.00249. Cela montre qu'une augmentation des concentrations de CH₄ est associée à une hausse mesurable des anomalies de température.

- Variation du dioxyde de carbone (CO₂_diff) : Le coefficient (0.149) est significatif au seuil de 1 %, indiquant que les hausses de CO₂ contribuent aussi à l'élévation des températures, dans une relation dynamique directe.

Qualité de l'ajustement :

- Le modèle présente un R² ajusté de 0.845, ce qui signifie que 84,5 % de la variance de la température est expliquée par les variables retenues. Cela témoigne d'une très bonne qualité d'ajustement.
- L'erreur standard des résidus est de 0.07, indiquant une bonne précision des prédictions.
- Les résidus sont globalement bien distribués (à vérifier par des tests de normalité et d'autocorrélation présentés ailleurs).

Le modèle ARDL met en évidence le rôle significatif et positif des gaz à effet de serre — en particulier du méthane (CH₄) et de la variation du CO₂ dans les dynamiques récentes des anomalies de température. Le modèle est bien ajusté, mais le retard de la température n'apporte pas d'information significative supplémentaire dans cette spécification. Cela suggère que les concentrations actuelles de GES suffisent à expliquer la tendance thermique à court terme.

4.4.3. Test de cointégration (Bounds F-test)

Le test de cointégration de Pesaran et al. (2001), ou Bounds Test de cointégration (Wald F-test), a été appliqué pour vérifier l'existence d'une relation d'équilibre de long terme entre les anomalies de température, les concentrations de CH₄ et les variations de CO₂.

Résultats du test de cointégration :

- Statistique F = 11.341
- p-value = 1e-06 (hautement significative)
- Hypothèse nulle H₀ : Pas de cointégration
- Hypothèse alternative H₁ : Cointégration possible

La valeur critique F étant largement supérieure aux seuils standards de Pesaran et al. (2001), et la p-value étant très inférieure à 0.05, on rejette l'hypothèse nulle d'absence de cointégration.

Il existe une relation de long terme stable entre les anomalies de température, le CH₄ et le CO₂.

4.4.4. Interprétation des relations de long terme

Le modèle ARDL a permis d'estimer la relation d'équilibre structurel entre la température et les GES. Plus précisément :

- Une hausse du CO₂ est associée à une élévation significative de la température à long terme, confirmant l'effet réchauffant de ce gaz.
- L'impact du méthane semble plus variable et dépendant de l'échelle temporelle, avec une influence moins marquée dans ce modèle.

4.4.5. Diagnostics du modèle

Les résidus du modèle ARDL ont été soumis à des tests de diagnostic :

- **Test d'autocorrélation résiduelle (test de Breusch-Godfrey)**

Afin de vérifier l'absence d'autocorrélation résiduelle dans le modèle ARDL, le test de Breusch-Godfrey a été appliqué à deux ordres successifs (1 et 2), ce qui permet de détecter une éventuelle dépendance temporelle non modélisée dans les erreurs (Tableau 9).

Tableau 9: Résultats du test de Breusch-Godfrey

Ordre du test	Statistique LM	DDL	p-value	Interprétation
1	0.112	1	0.7379	Non significatif
2	2.0436	2	0.3599	Non significatif

Les deux tests conduisent à des p-values largement supérieures à 0.05, ce qui signifie qu'on ne rejette pas l'hypothèse nulle d'absence d'autocorrélation. Les résidus du modèle ARDL peuvent donc être considérés comme non autocorrélés, renforçant la validité statistique du modèle.

- **Vérification de l'homoscédasticité des résidus du modèle ARDL**

Pour s'assurer que les erreurs du modèle respectent l'hypothèse d'homoscédasticité, deux tests ont été appliqués aux résidus du modèle ARDL : le test ARCH-LM et le test de Breusch-Pagan.

Test ARCH (Engle's LM test)

Ce test vise à détecter une hétéroscédasticité conditionnelle (effets ARCH) :

$$\chi^2 = 7.356, df = 5, p\text{-value} = 0.1955$$

H_0 : pas d'effet ARCH (variance constante dans le temps)

Résultat : $p > 0.05 \Rightarrow$ on ne rejette pas H_0 ; pas d'hétéroscédasticité conditionnelle significative détectée

Test de Breusch-Pagan (BP test)

Ce test général vérifie la dépendance de la variance des résidus aux variables explicatives :

$$BP = 4.8297, df = 3, p\text{-value} = 0.1847$$

H_0 : variance constante des résidus (homoscédasticité)

Résultat : $p > 0.05 \Rightarrow$ on ne rejette pas H_0 ; pas d'hétéroscédasticité structurelle significative

Les résultats concordants des deux tests montrent que les résidus du modèle ARDL ne présentent pas d'hétéroscédasticité significative. Cela valide l'hypothèse classique de variance constante, et conforte la robustesse des estimations et des inférences statistiques du modèle.

- **Vérification de la normalité des résidus du modèle ARDL**

Afin de s'assurer de la validité des inférences statistiques issues du modèle ARDL, il est essentiel de vérifier la normalité des résidus. Deux tests complémentaires ont été réalisés : le test de Jarque-Bera et le test de Shapiro-Wilk.

- **Test de Jarque-Bera :**

Statistique $\chi^2 = 0.475$, $df = 2$, p-value = 0.7884

H_0 : les résidus suivent une distribution normale

Résultat : $p > 0.05$; on ne rejette pas H_0

Les résidus sont compatibles avec une loi normale.

- Test de Shapiro-Wilk :

Statistique $W = 0.971$, p-value = 0.7527

H_0 : normalité des résidus

Résultat : $p > 0.05$; on ne rejette pas H_0

Aucun écart significatif à la normalité détecté.

Les deux tests concordent et indiquent que les résidus du modèle ARDL suivent une distribution normale au seuil de 5 %. Cela valide l'hypothèse de normalité des erreurs, condition requise pour la fiabilité des tests de Student sur les coefficients et pour la construction d'intervalles de confiance.

4.5. Non implémentation des modèles GARCH, VaR et EVT

Bien que l'étude initiale envisageait la possibilité de modéliser les risques climatiques à travers des approches inspirées de la finance, telles que les modèles GARCH, la Value-at-Risk (VaR) et la théorie des valeurs extrêmes (EVT), les diagnostics empiriques réalisés sur les séries ont conduit à écarter leur utilisation. Cette section justifie cette décision à partir des résultats obtenus.

Chapitre 5 : Discussion des résultats

Ce chapitre propose une interprétation critique des résultats obtenus à travers la modélisation des séries climatiques. Il les confronte à la littérature scientifique existante, confirme ou infirme les hypothèses formulées, et identifie les limites méthodologiques de l'étude.

5.1. Modélisation univariée : ARIMA

Les modèles ARIMA ont été utilisés pour modéliser séparément les dynamiques temporelles des anomalies de température, du CO₂, du CH₄ et du N₂O. Les tests de stationnarité (ADF) ont montré que toutes les séries étaient non stationnaires en niveau, confirmant la nécessité de les différencier. La température est intégrée d'ordre 1 (I(1)), tandis que le CO₂, CH₄ et le N₂O sont intégrés d'ordre 2 (I(2)). Ces résultats confirment l'hypothèse 1 selon laquelle les séries sont non stationnaires et requièrent une transformation préalable.

Les modèles ARIMA retenus, notamment ARIMA(1,1,3) pour les anomalies de température et ARIMA(2,2,3) pour le CO₂, ARIMA(2,2,0) pour le CH₄, et ARIMA(0,2,1) pour le N₂O ont montré une bonne adéquation aux données, des résidus sans autocorrélation, et des prévisions cohérentes à court et moyen terme. Ces performances sont en accord avec les travaux de Box et Jenkins (2015), qui soulignent la capacité des modèles ARIMA à modéliser des séries non stationnaires à tendance stochastique. Cela permet de confirmer l'hypothèse 2, selon laquelle les modèles ARIMA capturent efficacement les dynamiques des séries climatiques.

En revanche, les tests ARCH appliqués aux résidus des modèles ARIMA ont révélé des p-values systématiquement supérieures à 0,05. Il n'a donc pas été possible de confirmer l'existence d'une volatilité conditionnelle. Par conséquent, les approches GARCH, VaR ou EVT ont été jugées non applicables dans ce contexte. Cette conclusion infirme l'hypothèse 3, et rejoint les travaux de Coles (2001), qui précisent que les méthodes de modélisation des extrêmes nécessitent des séries à haute fréquence ou à variance instable, conditions absentes dans les données temporelles soumises à l'étude.

5.2. Cointégration et modélisation multivariée : ARDL

L'approche ARDL a été mobilisée pour explorer les liens de long terme entre anomalie de température globale (variable dépendante) et les concentrations de CO₂ et CH₄. Le test de cointégration de Pesaran (Bounds test) a permis de rejeter l'hypothèse nulle d'absence de

relation de long terme, avec une p-value significative ($< 0,01$). Ces résultats corroborent ceux du GIEC (2021) et de Meinshausen et al. (2009), qui insistent sur le rôle central du CO₂ dans l'évolution du climat mondial.

Le modèle ARDL a confirmé que le CO₂ différencié est significatif à long terme, ce qui valide empiriquement le rôle de ce gaz dans le forçage radiatif et le réchauffement global. Le CH₄ s'est également révélé significatif, renforçant l'idée qu'il contribue, bien que de manière moins durable, à l'augmentation des températures (Forster et al., 2023).

Ces constats permettent de confirmer l'hypothèse 4, à savoir l'existence d'une relation de cointégration à long terme entre les émissions de GES (CO₂, CH₄) et la température.

De plus, la combinaison des modèles ARIMA (pour les dynamiques individuelles) et ARDL (pour les relations structurelles) a permis une compréhension globale et robuste de l'évolution conjointe du climat et des émissions. Cela valide l'hypothèse 5, selon laquelle cette approche mixte permet d'extraire des enseignements pertinents tant sur le plan statistique que sur le plan interprétatif.

5.3. Limites de l'étude et perspectives

Plusieurs limites méthodologiques ont été identifiées au cours de cette étude, susceptibles d'influencer l'interprétation et la portée des résultats obtenus :

i) La première limite concerne la disponibilité inégale des données. Alors que les séries relatives à la température (1880-2024) et au dioxyde de carbone (1974-2024) sont relativement longues et bien documentées, celle du protoxyde d'azote (N₂O) ne couvre qu'une période restreinte de 23 années. Cette disparité limite la robustesse statistique de certains modèles, notamment pour les prévisions, et complique la comparabilité interséries.

ii) La seconde limite tient à la fréquence des données utilisées. L'analyse repose exclusivement sur des observations annuelles, ce qui empêche de capturer les variations saisonnières ou les épisodes extrêmes infra-annuels. L'absence de granularité temporelle réduit la capacité des modèles à détecter d'éventuelles volatilités conditionnelles, pourtant nécessaires pour appliquer des modèles comme GARCH ou des approches issues de la théorie des valeurs extrêmes (EVT), comme suggéré par Dritsaki et Dritsaki (2020).

À la lumière de ces limites, plusieurs pistes peuvent être envisagées pour approfondir les travaux :

- i) Il serait pertinent de recourir à des modèles multivariés dynamiques plus flexibles, tels que les modèles VAR, VECM ou SVAR, qui permettent une meilleure prise en compte des interdépendances entre variables, y compris en présence de chocs exogènes.
- ii) L'intégration de variables explicatives supplémentaires : comme la déforestation, les émissions industrielles, ou la consommation d'énergie permettrait d'enrichir l'analyse et de mieux cerner les déterminants exogènes du changement climatique.
- iii) Enfin, l'utilisation de données de plus haute fréquence, en particulier mensuelles ou journalières, ouvrirait la voie à l'estimation de modèles plus sensibles aux dynamiques de court terme, à la détection de chocs climatiques extrêmes, et à l'étude de la volatilité à travers des approches comme GARCH ou EVT.

5.4. Perspectives régionales et application en Afrique

Selon les évaluations du GIEC, la période de référence 1951-1980 est environ +0,3 à +0,4 °C plus chaude que l'ère préindustrielle (1850-1900) (IPCC, 2018). Ainsi, une anomalie de +1,2 °C correspond en réalité à un réchauffement d'environ +1,5 à +1,6 °C.

Bien que les analyses aient été menées à partir de données globales, les implications des résultats sont particulièrement significatives pour l'Afrique, et notamment pour l'Afrique de l'Ouest avec de telle augmentation de température. Cette région, fortement dépendante de l'agriculture pluviale et caractérisée par une faible résilience structurelle, est l'une des plus vulnérables aux effets du changement climatique induit par les gaz à effet de serre (Sultan et Gaetani, 2016). L'élévation de la température, les sécheresses récurrentes et la variabilité climatique affectent directement la productivité agricole, la sécurité alimentaire, les ressources hydriques et les conditions de vie des populations rurales.

Ainsi, les modèles statistiques mobilisés dans ce mémoire, bien qu'appliqués à des données mondiales, pourraient être adaptés à une échelle régionale pour analyser les dynamiques locales des GES et du climat. Une poursuite des recherches pourrait consister à appliquer ces approches (ARIMA, ARDL) à des séries temporelles africaines, telles que la température régionale, les émissions agricoles, ou encore l'indice de végétation NDVI (*Normalized Difference Vegetation Index*), un indicateur dérivé de l'imagerie satellitaire pour mesurer la santé de la végétation (Tucker, 1979). Cette orientation renforcerait la pertinence stratégique du travail et contribuerait à éclairer la formulation des politiques d'adaptation climatique sur le continent.

Chapitre 6 : Conclusion générale et suggestions

6.1. Conclusion générale

Ce mémoire avait pour objectif de modéliser l'évolution des anomalies de température globale et des concentrations de gaz à effet de serre (CO_2 , CH_4 , N_2O) au niveau planétaire à l'aide de modèles de séries temporelles, en particulier les modèles ARIMA et ARDL. Il visait également à explorer l'existence de relations de long terme entre les émissions de GES et les variations climatiques, dans un contexte de réchauffement global croissant.

L'analyse a porté sur des données climatiques annuelles couvrant différentes périodes (1880-2024 pour les anomalies de température, de 1974 à 2023 pour le CO_2 , de 1984 à 2024 pour le CH_4 et de 2001 à 2023 pour le N_2O). Les séries ont d'abord été explorées graphiquement et statistiquement. Les tests de stationnarité ont révélé que la température est intégrée d'ordre 1 ($I(1)$), tandis que le CO_2 , CH_4 et le N_2O sont intégrés d'ordre 2 ($I(2)$).

Les modèles ARIMA ont permis de capturer efficacement la dynamique propre à chaque série, avec des performances satisfaisantes en prévision, notamment pour les anomalies de température, le CO_2 , le CH_4 , et le N_2O . Les tests de résidus ont validé les hypothèses de non-autocorrélation et d'homoscédasticité, garantissant la solidité des estimations.

Le recours au modèle ARDL a permis d'identifier une relation de cointégration significative entre les anomalies de température et la concentration de CO_2 en différence et la concentration de CH_4 , mettant en évidence un lien de long terme entre les émissions de GES et le réchauffement climatique. Ces résultats sont en accord avec les observations du GIEC et la littérature scientifique existante.

En revanche, l'étude a montré que les séries analysées ne présentaient ni volatilité conditionnelle, ni comportements extrêmes justifiant l'usage de modèles GARCH, de Value-at-Risk (VaR) ou de la théorie des valeurs extrêmes (EVT).

6.2. Suggestions

Pour la recherche

- Approfondir l'analyse avec des données de plus haute fréquence (mensuelles ou journalières) afin d'identifier d'éventuels effets de volatilité ou de saisonnalité cachés.

- Étendre le panel de variables en intégrant d'autres facteurs climatiques (albédo, rayonnement solaire, vapeur d'eau) ou socioéconomiques (consommation d'énergie, activité industrielle).
- Explorer des modèles multivariés dynamiques plus avancés comme les modèles VAR, VECM ou les réseaux de neurones pour modéliser des interactions complexes.

Pour la décision publique et climatique

- Les résultats confirment une relation structurelle entre les GES (notamment le CO₂) et la température, ce qui renforce la nécessité de politiques de réduction des émissions ambitieuses.
- Une meilleure anticipation de l'évolution du climat passe par l'accès à des bases de données climatiques ouvertes, continues et de qualité.
- Il est recommandé de renforcer l'intégration de la modélisation statistique dans les outils de planification environnementale à long terme.

En définitive, ce travail apporte une contribution méthodologique et empirique utile à la compréhension des dynamiques climatiques, et ouvre la voie à des travaux futurs plus fins et multidimensionnels sur le changement climatique.

Bibliographie

Acemoglu, D., Aghion, P., Bursztyn, L., Hemous, D. (2012). *The Environment and Directed Technical Change*. *American Economic Review*, 102(1), 131–166. <https://doi.org/10.1257/aer.102.1.131>

Aghion, P., Dechezleprêtre, A., Hemous, D., Martin, R., Van Reenen, J. (2016). *Carbon Taxes, Path Dependency, and Directed Technical Change: Evidence from the Auto Industry*. *Journal of Political Economy*, 124(1). <https://doi.org/10.1086/684581>

Arnell, N., Brown, S., Gosling, S., Gottschalk, P., Hinkel, J., Huntingford, C., Lloyd-Hughes, B., Lowe, J., Nicholls, R., Osborn, T., Osborne, T., Rose, G., Smith, P., Wheeler, T. R., & Zelazowski, P. (2016). The impacts of climate change across the globe: A multi-sectoral assessment. *Climatic Change*, 134, 457–474. <https://doi.org/10.1007/s10584-014-1281-2>

Babaria, U., Florescu, I. (2025). *From volatility to profits: A GARCH and Random Forest–driven trading framework*. Stevens Faculty Publications.

Bangalore, M., Hallegatte, S., Bonzanigo, L., Kane, T., Fay, M., Narloch, U., Treguer, D., Rozenberg, J., Vogt-Schilb, A. (2016). *Shock Waves: Managing the Impacts of Climate Change on Poverty*. *Climate Change and Development*; World Bank. <http://hdl.handle.net/10986/22787>.

Batten, S., Sowerbutts, R., & Tanaka, M. (2016). *Let's talk about the weather: The impact of climate change on central banks*. Bank of England Staff Working Paper No. 603. <https://doi.org/10.2139/ssrn.2783753>

Bedoum, A., Biona, C.B., Bell, J-P., Adoum, I., Mbiake, R., Baohoutou, L. (2017). Évolution des indices des extrêmes climatiques en République du Tchad de 1960 à 2008, *Atmosphere-Ocean*, 55:1, 42-56, DOI: <https://doi.org/10.1080/07055900.2016.1268995>

Boehm, C. E., Flaaen, A., & Pandalai-Nayar, N. (2019). *Input linkages and the transmission of shocks: Firm-level evidence from the 2011 Tōhoku earthquake*. *The Review of Economics and Statistics*, 101(1), 60–75.

- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Box, G. E. P., Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.
- Caminade, C., Kovats, S., Rocklov, J., Tompkins, A. M., Morse, A. P., Colón-González, F. J., Hans, S., Martens, P., Lloyd, S. J. (2014). *Impact of climate change on global malaria distribution*. *Proceedings of the National Academy of Sciences*, 111(9), 3286–3291. <https://doi.org/10.1073/pnas.1302089111>
- Carleton, T. A., Hsiang, S. (2016). Social and economic impacts of climate. *Science*, 353. <https://doi.org/10.1126/science.aad9837>
- Carson, R. (1962). *Printemps silencieux*. Paris : Plon.
- Chakraborty, N. (2023). Testing RNN-LSTM Forecasting with Simulated Time-Series: Exploring Univariate Sensitivity. Preprints. <https://doi.org/10.20944/preprints201907.0241.v2>
- Chattopadhyay, A., Hassanzadeh, P., Pasha, S. (2020). Predicting clustered weather patterns: A test case for applications of convolutional neural networks to spatio-temporal climate data. *Scientific Reports*, 10(1), 10.1038/s41598-020-57897-9
- Coles, S. (2001). *Introduction to statistical modeling of extreme values*. Springer. <https://doi.org/10.1007/978-1-4471-3675-0>
- Dasgupta, P. (2021). *The Economics of Biodiversity: The Dasgupta Review*. HM Treasury.
- Dickey, D. A., Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427–431. <https://doi.org/10.2307/2286348>
- Drake, J. (2014). *Climate Modeling for Scientists and Engineers*. SIAM. <https://doi.org/10.1137/1.9781611973549>
- Dritsaki, M., & Dritsaki, C. (2020). Forecasting European Union CO2 Emissions Using Autoregressive Integrated Moving Average-Autoregressive Conditional Heteroscedasticity

Models. *International Journal of Energy Economics and Policy*, 10, 411-423.
<https://doi.org/10.32479/ijeep.9186>

Ducharne, A., Sauquet, E., Habets, F., Deque, M., Gascoïn, S., Hachour, A., Martin, E., Oudin, L., Page, P., Terray, L., Thiery, D., Viennot, P. (2011). Évolution potentielle du régime des crues de la Seine sous changement climatique, *La Houille Blanche*, 97:1, 51-57, DOI: 10.1051/lhb/2011006

Dufresne, J-L., Royer, J-F. (2008). Simulation de l'évolution du climat aux échelles globales et régionales. *La Houille Blanche*, 2 : 1-5p

Ellen MacArthur Foundation. (2013). *Towards the Circular Economy*.
<https://ellenmacarthurfoundation.org>

Ellerman, D.A., Convery, F., de Perthuis, C. (2010). *Pricing Carbon: The European Union Emissions Trading Scheme*. Cambridge University Press.

Enders, W. (2015). *Applied Econometric Time Series* (4th ed.). Wiley.

Engle, R. F. (1982). Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
<https://doi.org/10.2307/1912773>

Engle, R. F., Granger, C. W. J. (1987). Co-integration and error correction: Representation, estimation, and testing. *Econometrica*, 55(2), 251–276. <https://doi.org/10.2307/1913236>

European Commission. (2021). *EU taxonomy for sustainable activities*.
https://ec.europa.eu/info/business-economy-euro/banking-and-finance/sustainable-finance/eu-taxonomy-sustainable-activities_en

Forster, P., Ramaswamy, V., Artaxo, P., Berntsen, T., Betts, R., Fahey, D.W., Haywood, J., Lean, J., Lowe, D.C., Myhre, G., Nganga, J., Prinn, R., Raga, G., Schulz M., Van Dorland, R. (2007): The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

Forster, P. M., Smith, C. J., Allen, M. R., et al. (2023). *Indicators of Global Climate Change 2022: Annual update of large-scale indicators of the state of the climate system and human*

influence. Earth System Science Data, 15(2295), 2295–2361.
<https://doi.org/10.5194/essd-15-2295-2023>

Grimm, N. B., Chapin, F. S., Bierwagen, B., Gonzalez, P., Groffman, P. M., Luo, Y., Melton, F., Nadelhoffer, K., Pairis, A., Raymond, P. A., Schimel, J. P., & Williamson, C. E. (2013). The impacts of climate change on ecosystem structure and function. *Frontiers in Ecology and the Environment*, 11, 474-482. <https://doi.org/10.1890/120282>

Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC). (2021). *Rapport d'évaluation AR6*.

Gujarati, D. N., Porter, D. C. (2009). *Basic Econometrics* (5th ed.). McGraw-Hill Education.

Guo, L., Perrie, W., Long, Z., Toulany, B., Sheng, J. (2015). The Impacts of Climate Change on the Autumn North Atlantic Wave Climate, *Atmosphere-Ocean*, 53:5, 491-509, DOI: 10.1080/07055900.2015.1103697

Haines, A., Kovats, R. S., Campbell-Lendrum, D., Corvalan, C. (2006a). Climate change and human health: Impacts, vulnerability, and mitigation. *The Lancet*, 367(9528), 2101–2109. [https://doi.org/10.1016/S0140-6736\(06\)68933-2](https://doi.org/10.1016/S0140-6736(06)68933-2)

Haines, A., Kovats, R. S., Campbell-Lendrum, D., Corvalán, C. (2006b). *Climate change and human health: Impacts, vulnerability and public health*. *Public Health*, 120(7), 585–596. <https://doi.org/10.1016/j.puhe.2006.01.002>

Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press.

Hebesiba Beula, D., & Srinivasan, S., Nanda Kumar, C.D. (2021). *Prediction of climate change using ARIMA model*. *YMER*, 20(12) : 230-245

Herman, G.R., Schumacher, R.S. (2018). Money Doesn't Grow on Trees, but Forecasts Do: Forecasting Extreme Precipitation with Random Forests. *Monthly Weather Review*, 146(5), 1571-1600

Hoegh-Guldberg, O., Jacob, D., Taylor, M., Bindi, M., Brown, S., Camilloni, I., Diedhiou, A., Djalante, R., Ebi, K. L., Engelbrecht, F., Guiot, J., Hijioka, Y., Mehrotra, S., Payne, A., Seneviratne, S. I., Thomas, A., Warren, R., & Zhou, G. (2018). Impacts of 1.5°C Global Warming on Natural and Human Systems. *Nature*, 559(7714), 211–220. <https://doi.org/10.1038/s41586-018-0594-0>

Hyndman, R. J., Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>

IEA. (2022). *World Energy Investment 2022*. International Energy Agency. <https://www.iea.org/reports/world-energy-investment-2022>

IMF (International Monetary Fund). (2020). *Climate Change: Risk to Stability*. In *Global Financial Stability Report*.

Intergovernmental Panel on Climate Change (IPCC). (2018). *Global warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels*. <https://www.ipcc.ch/sr15/chapter/chapter-1/>

Intergovernmental Panel on Climate Change (IPCC). (2021). *Climate Change 2021: The Physical Science Basis. Summary for Policymakers*. Cambridge University Press.

NASA. (2023). *Climate change: How do we know?* <https://climate.nasa.gov/evidence/>

IPCC (2021). Summary for Policymakers. *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press. <https://www.ipcc.ch/report/ar6/wg1>

IPCC. (2022). *Climate Change 2022: Impacts, Adaptation and Vulnerability*. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. <https://www.ipcc.ch/report/ar6/wg2/>

Islam, S. N., & Winkel, J. (2017). *Climate Change and Social Inequality*. UN/DESA Working Paper No. 152.

Jeffry, L., Ong, M., Nomanbhay, S., Mofijur, M., Mubashir, M., & Show, P. (2021). Greenhouse gases utilization: A review. *Fuel*, 301(121017). <https://doi.org/10.1016/J.FUEL.2021.121017>

Jorion, P. (2006). *Value at Risk: The New Benchmark for Managing Financial Risk* (3rd ed.). McGraw-Hill.

Kjellstrom, T., Holmer, I., & Lemke, B. (2009). *Workplace heat stress, health and productivity - an increasing challenge for low and middle-income countries during climate change*. *Global Health Action*, 2(1), 1-6. <https://doi.org/10.3402/gha.v2i0.2047>

- Liu, Y., Zhai, J., Zhang, X. (2024). "Automated Prediction and Sustainable Management of Global Warming Impact on Power Systems: A Hybrid ARIMA-BP Neural Network Approach," *2024 IEEE 2nd International Conference on Image Processing and Computer Applications (ICIPCA)*, Shenyang, China, 2024, pp. 738-741, doi: 10.1109/ICIPCA61593.2024.10709223.
- Masson-Delmotte, V., Zhai, P., Pirani, A., et al. (Eds.). (2021). Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. *Summary for Policymakers*. In: *Climate Change 2021: The Physical Science Basis*. IPCC. <https://doi.org/10.1017/9781009157896>.
- Meadows, D. H., Meadows, D. L., Randers, J., Behrens III, W. W. (1972). *The Limits to Growth: A Report for the Club of Rome's Project on the Predicament of Mankind*. New York: Universe Books.
- Meinshausen, M., Meinshausen, N., Hare, W., Raper, S. C. B., Frieler, K., Knutti, R., Frame, D. J., Allen, M. R. (2009). *Greenhouse-gas emission targets for limiting global warming to 2 °C*. *Nature*, 458(7242), 1158–1162. <https://doi.org/10.1038/nature08017>
- Morton, J. F. (2007). The impact of climate change on smallholder and subsistence agriculture. *Proceedings of the National Academy of Sciences*, 104, 19680–19685. <https://doi.org/10.1073/pnas.0701855104>
- Nadiga, B. (2021). Reservoir Computing as a Tool for Climate Predictability Studies. *Journal of Advances in Modeling Earth Systems*, 13. <https://doi.org/10.1029/2020MS002290>
- NASA GISS (Goddard Institute for Space Studies). (2023). *GISS Surface Temperature Analysis (GISTEMP)*. <https://data.giss.nasa.gov/gistemp>
- National Oceanic and Atmospheric Administration (NOAA). (2023). *Global Surface Temperature Anomalies*. Retrieved from <https://www.ncdc.noaa.gov/>
- Navarra, A., Tribbia, J., Conti, G. (2012). The Path Integral Formulation of Climate Dynamics. *PLoS ONE*, 8(6). <https://doi.org/10.1371/journal.pone.0067022>
- NOAA (National Oceanic and Atmospheric Administration). (2023). *Climate Change: Global Temperature*. <https://www.climate.gov>
- Nordhaus, W. D. (1994). *Managing the Global Commons: The Economics of Climate Change*. MIT Press.

- Nordhaus, W. D. (2017). *Revisiting the social cost of carbon*. Proceedings of the National Academy of Sciences, 114(7), 1518–1523. <https://doi.org/10.1073/pnas.1609244114>
- Nordhaus, W. D. (2019). *Climate Change: The Ultimate Challenge for Economics*. *American Economic Review*, 109(6), 1991-2014.
- OECD. (2015). *The Economic Consequences of Climate Change*. OECD Publishing. <https://doi.org/10.1787/9789264235410-en>
- OECD. (2019). *Taxing Energy Use 2019: Using Taxes for Climate Action*. Organisation for Economic Co-operation and Development. <https://doi.org/10.1787/058ca239-en>
- Pesaran, M. H., Shin, Y., Smith, R. J. (2001). Bounds testing approaches to the analysis of level relationships. *Journal of Applied Econometrics*, 16(3), 289–326. <https://doi.org/10.1002/jae.616>
- Pidwirny, M. (2011). *Precipitation*. In *Fundamentals of Physical Geography* (2nd ed.).
- IPCC. (2021). *Climate Change 2021*.
- Pigou, A. C. (1920). *The Economics of Welfare*. Macmillan.
- Rakotoarimanana, R. S., Ramahefy, T. R., Randriamaroson, R. M., Rastefano, E. (2025). *Global temperature prediction by convolutional neural network (CNN)*. *European Journal of Applied Science, Engineering and Technology*, 3(1), 99–109. [https://doi.org/10.59324/ejaset.2025.3\(1\).08](https://doi.org/10.59324/ejaset.2025.3(1).08)
- Roberts, J. T., & Parks, B. C. (2007). *A Climate of Injustice: Global Inequality, North–South Politics, and Climate Policy*. MIT Press.
- Scheffers, B. R., De Meester, L., Bridge, T. C. L., Hoffmann, A. A., Pandolfi, J. M., Corlett, R. T., Butchart, S. H. M., Pearce-Kelly, P., Kovacs, K. M., Dudgeon, D., Pacifici, M., Rondinini, C., Foden, W. B., Martin, T. G., Mora, C., Bickford, D., Watson, J. E. M. (2016). The broad footprint of climate change from genes to biomes to people. *Science*, 354(6313). <https://doi.org/10.1126/science.aaf7671>
- Shahidul, M. (2019). An insight on the greenhouse gas emission from the metals process industries and its effects on climate change. *Material Science & Engineering International Journal*. <https://doi.org/10.15406/mseij.2019.03.00115>

- Springmann, M., Godfray, H. C. J., Rayner, M., & Scarborough, P. (2016a). *Analysis and valuation of the health and climate change cobenefits of dietary change*. Proceedings of the National Academy of Sciences, 113(15), 4146–4151. <https://doi.org/10.1073/pnas.1523119113>
- Springmann, M., Mason-D’Croz, D., Robinson, S., Garnett, T., Godfray, H. C. J., Gollin, D., Rayner, M., Ballon, P., Scarborough, P. (2016b). Global and regional health effects of future food production under climate change: A modelling study. *The Lancet*, 387, 1937-1946. [https://doi.org/10.1016/S0140-6736\(15\)01156-3](https://doi.org/10.1016/S0140-6736(15)01156-3)
- Sterman, J. D. (2000). *Business Dynamics: Systems Thinking and Modeling for a Complex World*. McGraw-Hill Education.
- Stern, N. (2007). *The Economics of Climate Change: The Stern Review*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511817434>
- Stiglitz, J. E., Sen, A., & Fitoussi, J.-P. (2009). *Report by the Commission on the Measurement of Economic Performance and Social Progress*.
- Stiglitz, J. E., Stern, N., Duan, M., Edenhofer, O., Giraud, G., Heal, G., Lebre la Rovere, E., Morris, A., Moyer, E., Pangestu, M., Shukla, P.R., Sokona, Y., Winkler, H. (2017). *Report of the High-Level Commission on Carbon Prices*. Carbon Pricing Leadership Coalition, World Bank Group.
- Sultan, B., Gaetani, M. (2016). Agriculture in West Africa in the twenty-first century: climate change and impacts scenarios, and potential for adaptation. *Frontiers in Plant Science*, 7, 1262. <https://doi.org/10.3389/fpls.2016.01262>
- Tol, R. S. J. (2018). The Economic Impacts of Climate Change. *Review of Environmental Economics and Policy*, 12, 4–25. <https://doi.org/10.1093/reep/rex027>
- Trenberth, K. E. (2011). Changes in precipitation with climate change. *Climate Research*, 47(1-2), 123–138. <https://doi.org/10.3354/cr00953>
- Tsay, R. S. (2010). *Analysis of Financial Time Series* (3rd ed.). Wiley.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127-150.
- Walsh, J., McGehee, R. (2013). Modeling Climate Dynamically. *The College Mathematics Journal*, 44(5), 350–363. <https://doi.org/10.4169/college.math.j.44.5.350>

- Walther, G.-R., Post, E., Convey, P., Menzel, A., Parmesan, C., Beebee, T. J. C., Fromentin, J.-M., Hoegh-Guldberg, O., & Bairlein, F. (2002). Ecological responses to recent climate change. *Nature*, 416, 389–395. <https://doi.org/10.1038/416389a>
- WEF. (2023). *Global Risks Report 2023*. World Economic Forum.
- Wei, C., Wang, M. (2020). Spatial distribution of greenhouse gases (CO₂ and CH₄) on expressways in the megacity Shanghai, China. *Environmental Science and Pollution Research*, 27(31143–31152). <https://doi.org/10.1007/s11356-020-09372-1>
- Wheeler, T., von Braun, J. (2013). Climate Change Impacts on Global Food Security. *Science*, 341(6145), 508–513. <https://doi.org/10.1126/science.1239402>
- WHO. (2021). *Climate change and health*. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/climate-change-and-health>
- Xin, Z. (2001). Greenhouse effect and global climate warming. *Journal of Qinghai Normal University*. https://consensus.app/papers/greenhouse-effect-and-global-climate-warming-xin/b4576c21c645534d9c4e65f77a9f9056/?utm_source=chatgpt
- Xu, Z., Han, Y., Yang, Z. (2018). Dynamical downscaling of regional climate: A review of methods and limitations. *Science China Earth Sciences*, 62(3), 365–375. <https://doi.org/10.1007/s11430-018-9261-5>
- Young, H. D., Freedman, R. A. (2019). *University Physics with Modern Physics* (15th ed.). Pearson Education.
- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175,
- Zhang, H., Fan, X., Xu, M., Chou, J. (1998). Application of a Global Analysis Method to a Simplified Climate Model. *Theoretical and Applied Climatology*, 61, 103–111. <https://doi.org/10.1007/S007040050055>
- Zhang, X., Vincent, L. A., Hogg, W. D., Niitsoo, A. (2000). Temperature and precipitation trends in Canada during the 20th century. *Atmosphere-Ocean*, 38(3), 395–429. <https://doi.org/10.1080/07055900.2000.9649654>

Annexes




Figure 16: Pouvoir de Réchauffement global des gaz à effet de serre

1. INSTALLER ET CHARGER LES LIBRAIRIES

```
install.packages(c("rnoaa", "dplyr", "lubridate", "xts", "forecast", "rugarch", "evir", "ggplot2"))
```

```
library(rnoaa)
```

```
library(dplyr)
```

```
library(lubridate)
```

```
library(forecast)
```

```
library(rugarch)
```

```
library(evir)
```

```
library(ggplot2)
```

2. MODÉLISATION ARIMA

```

model_arima <- auto.arima(ts_temp)
forecast_arima <- forecast(model_arima, h = 12)
plot(forecast_arima, main = "Prévision ARIMA - Température mensuelle")

# Ajuster un modèle ARIMA sur les données d'entraînement
model_arima_tp <- auto.arima(temp_train)
summary(model_arima_tp)
library(lmtest)
coeftest(model_arima_tp)

# SELECTION DE MODELE ARIMA PAR AIC
library(forecast)

aic_matrix <- matrix(NA, nrow = 4, ncol = 4)
rownames(aic_matrix) <- 0:3
colnames(aic_matrix) <- 0:3

for(p in 0:3){
  for(q in 0:3){
    fit <- Arima(temp_train, order = c(p, 1, q))
    aic_matrix[p+1, q+1] <- AIC(fit)
  }
}
aic_matrix # pour voir quel (p,q) minimise l'AIC

# Résidus
checkresiduals(model_arima_tp)

# Prévision
forecast_arima_tp <- forecast(model_arima_tp, h = 25) # Prévision sur 10 ans

```

```
autoplot(forecast_arima_tp)
```

```
accuracy(forecast_arima_tp, temp_test)
```

```
# 3. ARDL
```

```
model_ardl_auto <- auto_ardl(temp_anomalie ~ ch4_ppb + co2_diff,  
                             data = ges_data_diff,  
                             max_order = 3)
```

```
summary(model_ardl_auto)
```

```
summary(model_ardl_auto$best_model)
```

```
AIC(model_ardl_auto$best_model)
```

```
# 4. TEST D'AUTOCORRELATION DE BREUSH GODFREY
```

```
library(lmtest)
```

```
model_ardl <- model_ardl_auto$best_model
```

```
# Test de Breusch-Godfrey avec 1 ou 2 lags
```

```
bgtest(model_ardl, order = 1)
```

```
bgtest(model_ardl, order = 2)
```