

**UNIVERSITE NATIONALE DU VIETNAM, HANOI
ECOLE INTERNATIONALE**

=====



NZAZI NGABILA BOAZ

**ANALYSE PRÉDICTIVE ET CAUSALE DE L'EXÉCUTION DES
DÉPENSES PUBLIQUES EN RDC (1996–2023) PAR
APPRENTISSAGE AUTOMATIQUE**

**PHÂN TÍCH DỰ ĐOÁN VÀ NHÂN QUẢ VỀ THỰC THI CHI
TIÊU CÔNG TẠI CHDC CONGO (1996–2023) BẰNG PHƯƠNG
PHÁP HỌC MÁY**

Programme : Systèmes intelligents et Multimédias

Code : 8480201.02

Encadrants : Pr. Dr. Selain Kasereka Kabunga

Dr. Nguyễn Quang Thuận

Kinshasa - 2026

UNIVERSITE NATIONALE DU VIETNAM, HANOI
ECOLE INTERNATIONALE

=====



NZAZI NGABILA BOAZ

**ANALYSE PRÉDICTIVE ET CAUSALE DE L'EXÉCUTION DES
DÉPENSES PUBLIQUES EN RDC (1996–2023) PAR
APPRENTISSAGE AUTOMATIQUE**

**PHÂN TÍCH DỰ ĐOÁN VÀ NHÂN QUẢ VỀ THỰC THI CHI
TIÊU CÔNG TẠI CHDC CONGO (1996–2023) BẰNG PHƯƠNG
PHÁP HỌC MÁY**

Programme : **Systèmes intelligents et Multimédias**

Code : **8480201.02**

Encadrants : **Pr. Dr. Selain Kasereka Kabunga**

Dr. Nguyễn Quang Thuận

Kinshasa - 2026

Attestation sur l'honneur

— * * * —

Je déclare par la présente que ce mémoire a été réalisé par moi-même sous la direction et la supervision de **Prof. Dr. Selain Kasereka Kabunga** et de **Dr. Nguyễn Quang Thuận**; et que les travaux et les résultats qu'il contient sont conformes à la réalité de l'auteur et respectent l'éthique de la recherche. Les données et figures présentées dans ce mémoire proviennent de mes propres analyses, commentaires et évaluations, et s'appuient sur diverses sources dûment référencées.

De plus, les autres commentaires, analyses et données utilisés par d'autres auteurs et organisations ont été explicitement mentionnés.

J'assume l'entière responsabilité de toute fraude détectée dans mon mémoire.


Kinshasa, 30 Juillet 2026



NZAZI NGABILA Boaz


Approuvé par :

ENCADRANT 1



Pr. Dr. Selain Kasereka Kabunga

ENCADRANT 2



Dr. Nguyễn Quang Thuận

Publications

Les travaux conduits dans le cadre de ce mémoire ont donné lieu à plusieurs publications et communications scientifiques dans des revues et conférences internationales à comité de lecture. Ces contributions témoignent de l’ancrage de la recherche dans la littérature académique et de sa diffusion auprès de la communauté scientifique spécialisée en intelligence artificielle appliquée aux finances publiques.

1. **Nzazi, B. N., Biaba, J. K., Bazie, I. G., Tashev, T., Kambale, W. V., Tuong, V. H., ... & Kasereka, S. K.** (2025). Artificial intelligence for public expenditure analysis in low-income countries : Opportunities and challenges. *Procedia Computer Science*, **272**, 261–268.
<https://doi.org/10.1016/j.procs.2025.10.204>
 2. **Nzazi, B. N., & Kasereka, S. K.** (2026). A data-driven decision support system for public expenditure analysis and budget optimization in the DR Congo. Accepted for oral presentation at the Workshop *AI2M4RI*, Athens, Greece, 18–20 August 2026. To be published in *Procedia Computer Science*, Elsevier.
 3. **Nzazi, B. N., & Kasereka, S. K.** (2026). A predictive–causal machine learning framework for public expenditure execution : Evidence from the DRC (1996–2023). Submitted to *IEEE Access* (Q1).
-

Remerciements

Ce mémoire est le fruit d'un parcours exigeant, et il n'aurait pas abouti sans le concours de plusieurs personnes que je tiens à remercier ici, non par convention, mais parce que leur apport a été réel.

Je pense d'abord au **Professeur Docteur Selain Kasereka Kabunga** et au **Dr. Nguyễn Quang Thuận**, mes directeurs de mémoire. Ce qui m'a le plus marqué dans leur encadrement, c'est leur capacité à poser les bonnes questions au bon moment, celles qui obligent à aller plus loin que ce qu'on avait prévu. Plusieurs choix méthodologiques de ce travail portent l'empreinte de nos échanges.

Je dois beaucoup aussi au **Professeur Docteur Ho Tuong Vinh** de l'École Internationale de l'Université Nationale du Vietnam, Hanoi. Ses enseignements ont été pour moi bien plus que des cours : ils ont changé ma façon de raisonner sur les données et sur ce qu'on peut en tirer.

Mon stage au laboratoire **ABIL** de l'Université de Kinshasa, sous la supervision du **Professeur Docteur Nathanaël Kasoro Mulenda**, a été une expérience que je n'oublierai pas. C'est là que j'ai pu tester concrètement les méthodes développées dans ce mémoire, dans un environnement où les données sont imparfaites, les délais courts et les enjeux bien réels. Cette confrontation avec le terrain a profondément enrichi ma réflexion.

Je remercie également le **Docteur Christian Mulomba Mukendi**, de Kyung-sung University à Busan, en République de Corée, pour ses retours scientifiques toujours précis et pour sa disponibilité malgré la distance.

À l'ensemble du corps professoral de l'École Internationale et à mes collègues de promotion : les discussions que nous avons eues, parfois informelles, ont enrichi ce travail.

Un mot enfin pour ma famille, et surtout pour mon épouse **Odette Bofio**. Mener un master à distance, avec tout ce que cela implique de sacrifices quotidiens, n'est pas une aventure solitaire. Sa patience et sa confiance ont été, dans les moments difficiles, ce qui m'a permis de continuer.

À tous ceux qui ont, de près ou de loin, contribué à ce parcours : merci.

NZAZI NGABILA Boaz

Résumé

Les applications du machine learning aux finances publiques se concentrent majoritairement sur des pays à revenu élevé ou intermédiaire. Les États fragiles africains restent presque absents de la littérature empirique. Une limite conceptuelle traverse en outre ces travaux : la prédiction et l'identification causale y sont traitées comme des exercices équivalents. Or une variable qui améliore la précision d'un modèle prédictif n'est pas nécessairement un levier sur lequel une réforme peut agir. Dans les finances publiques, le taux d'exécution de l'année précédente est le meilleur prédicteur du taux de l'année suivante. Mais cette persistance statistique ne constitue pas une cause : elle reflète la capacité institutionnelle accumulée, l'érosion monétaire ou la dépendance aux cycles miniers. Confondre prédiction et causalité conduit à cibler les mauvaises variables dans la conception des politiques publiques.

Ce mémoire comble ces deux lacunes en développant un cadre analytique combinant prédiction et causalité pour l'exécution des dépenses publiques en République Démocratique du Congo (RDC) sur la période 1996–2023. Le contexte retenu est particulièrement exigeant : deux guerres civiles, une instabilité politique prolongée, une hyperinflation culminant à 514 % et une dépendance structurelle aux cycles miniers. Un panel original de 784 observations couvrant 28 fonctions budgétaires sur 28 ans a été constitué à partir des rapports annuels de la Banque Centrale du Congo, enrichi par des données du FMI et de la Banque mondiale.

Les résultats montrent que les dépenses courantes atteignent un niveau de prévisibilité acceptable ($R^2 = 0,445$ avec Random Forest). Les dépenses en capital résistent à toute modélisation prédictive ($R^2 < 0$) : leurs déterminants réels sont largement exogènes au système budgétaire formel. L'analyse par Double Machine Learning identifie quatre mécanismes causaux robustes : la persistance administrative ($\hat{\theta} = +0,488$, $\text{FDR} < 1\%$), l'effet ciseaux budgétaires lié au taux de change ($-0,239$), les rentes minières ($+0,116$) et la capacité institutionnelle ($+0,115$). La validation externe sur l'Angola montre que certains mécanismes se généralisent, d'autres non, confirmant l'absence de modèle universel pour les États fragiles.

Ce travail produit un cadre analytique reproductible pour l'étude de l'exécution budgétaire dans les États fragiles africains, un système d'alerte précoce opérationnel (83 % de rappel sur la sous-exécution) et des recommandations de politique publique fondées sur des effets causaux estimés.

Mots-clés : Machine Learning, Causal Machine Learning, Double Machine Learning, Dépenses publiques, RDC, Angola, Analyse budgétaire, SHAP, Interprétabilité, Politique publique.

Abstract

Machine learning applications to public finance have predominantly focused on high- and middle-income countries. Fragile African states remain largely absent from the empirical literature. A conceptual limitation further characterizes this body of work : prediction and causal identification are routinely treated as equivalent exercises. A variable that improves forecast accuracy is not necessarily one that policymakers can act on. This conflation leads to targeting the wrong levers in reform design.

This thesis addresses both gaps by developing a predictive and causal analytical framework for public expenditure execution in the Democratic Republic of Congo (DRC) over the period 1996–2023. The DRC constitutes an unusually demanding research setting : two civil wars, hyperinflation peaking at 514%, and a structural dependence on commodity cycles. A novel panel dataset of 784 observations covering 28 budget functions over 28 years was constructed from primary sources not previously mobilized in the academic literature.

Current expenditures are moderately predictable ($R^2 = 0.445$ with Random Forest). Capital expenditures resist all predictive modelling ($R^2 < 0$), because their real determinants lie largely outside the formal budget system. A Double Machine Learning framework identifies four robust causal mechanisms : administrative persistence ($\hat{\theta} = +0.488$, $\text{FDR} < 1\%$), exchange rate erosion (-0.239), natural resource rents ($+0.116$), and institutional capacity ($+0.115$). External validation on Angola shows that some mechanisms generalize across fragile states while others are context-specific, ruling out any universal model of budget execution.

This work provides a replicable analytical framework for budget execution analysis in fragile African states, an operational early warning classifier achieving 84,3% recall on under-execution episodes, and concrete policy recommendations grounded in causal evidence rather than predictive associations alone.

Keywords : Machine Learning, Causal Machine Learning, Double Machine Learning, Public Expenditure, DRC, Angola, Budget Execution, SHAP, Interpretability, Public Policy.

Liste des abréviations

API :	Application Programming Interface
ATE :	Average Treatment Effect
AUC :	Area Under the Curve
BCC :	Banque Centrale du Congo
CATE :	Conditional Average Treatment Effect
CDF :	Franc Congolais
CF :	Causal Forest
DAG :	Directed Acyclic Graph
DiD :	Difference-in-Differences
DML :	Double Machine Learning
EDA :	Exploratory Data Analysis
F1-Score :	F1 Score
FDR :	False Discovery Rate
FMI :	Fonds Monétaire International
GB :	Gradient Boosting
GDP :	Gross Domestic Product
GroupKFold :	Group K-Fold Cross-Validation
IA :	Intelligence Artificielle
IMF :	International Monetary Fund
IV :	Instrumental Variables
KFold :	K-Fold Cross-Validation
LIC :	Low-Income Countries
MAE :	Mean Absolute Error
ML :	Machine Learning
ODA :	Official Development Assistance
OLS :	Ordinary Least Squares
PDF :	Portable Document Format

PIB :	Produit Intérieur Brut
R² :	Coefficient of Determination
RD :	Regression Discontinuity
RDC :	République Démocratique du Congo
RF :	Random Forest
RMSE :	Root Mean Squared Error
SE :	Standard Error
SHAP :	SHapley Additive exPlanations
SIGFIP :	Système Intégré de Gestion des Finances Publiques
TOFE :	Tableau des Opérations Financières de l'État
WDI :	World Development Indicators
WEO :	World Economic Outlook
WGI :	Worldwide Governance Indicators
XAI :	Explainable Artificial Intelligence
XGB :	XGBoost (eXtreme Gradient Boosting)

Liste des tableaux

2	Bureau Exécutif du Laboratoire ABIL	19
1.1	État de l’art et Revue critique des travaux existants	26
2.1	Les quatre régimes budgétaires de la RDC (1996–2023)	34
3.1	Exemples d’harmonisation ministérielle par algorithme regex	43
3.2	Sources de données, Panel RDC et Angola	43
3.3	Variables de traitement DML, mécanismes et signes attendus — RDC (1996–2023)	45
3.4	Dictionnaire des 26 variables — Panel RDC (1996–2023)	47
3.5	Structure des valeurs manquantes	49
3.6	Comparaison des panels RDC et Angola	51
3.7	Les quatre étapes du pipeline méthodologique	52
3.8	Les trois étapes du DML	56
3.9	Récapitulatif des choix méthodologiques	58
4.1	Performances prédictives des Dépenses courantes (validation croisée temporelle, 5 folds, 784 obs)	60
4.2	Performances de classification des Régimes d’exécution (ensemble de test 2016–2023)	62
4.3	Importance SHAP des Dépenses courantes (XGBoost, 784 obs, 1999– 2023)	64
4.4	DML, Dépenses courantes (1999–2023, SE clusterisées par année, 10 répétitions)	66
4.5	DML – Dépenses en capital (1999–2023, SE clusterisées par année, 10 répétitions)	67
4.6	Synthèse des quatre mécanismes causaux et implications de politique publique	69
4.7	Robustesse des quatre mécanismes causaux sur différentes fenêtres temporelles	70
4.8	Artefacts nominaux, Inflation et croissance du PIB testées comme trai- tements	71
4.9	Comparaison causale RDC vs Angola : convergence et divergence des mécanismes	73
A.1	Fonctions budgétaires harmonisées : RDC (1996–2023)	86

Table des figures

2.1	Effet ciseaux budgétaires en RDC (mécanisme causal C2).	35
3.1	Pipeline de construction du panel RDC (1996–2023).	41
3.2	DAG causal : traitements, confondeurs et outcomes.	54
4.1	Matrice de confusion – Random Forest	62
4.2	Distribution réelle vs prédite des régimes d'exécution, Random Forest (2016–2023).	63
4.3	Décalage entre importance SHAP et effet causal DML.	65
B.1	Synthèse globale du pipeline ML, RDC (1996–2023).	89
C.1	Interface de visualisation du dashboard.	91
C.2	Interface de performance ML du dashboard.	91

Table des matières

Attestation sur l'honneur	1
Publications	2
Remerciements	3
Résumé	4
Abstract	5
Liste des abréviations	6
Liste des tableaux	8
Table des figures	9
Introduction générale	14
1. Contexte et motivation	14
2. Problématique	14
3. Questions de recherche	15
4. Hypothèses de recherche	15
5. Objectifs	16
6. Démarche méthodologique	17
7. Contribution de l'étude	18
8. Cadre institutionnel d'accueil	18
9. Structure du mémoire	19
1 Cadre Théorique et Etat de l'Art	20
1.1 Introduction	20
1.2 L'exécution budgétaire comme objet d'analyse	20
1.2.1 Définition et enjeux conceptuels	20
1.2.2 Les déterminants de l'exécution budgétaire dans les pays à faible revenu	21
1.2.3 Limites des approches économétriques classiques	21
1.3 L'apprentissage automatique en économie publique	22
1.3.1 Principes généraux	22
1.3.2 Les méthodes d'ensemble : Random Forest et XGBoost	22
1.3.3 L'explicabilité : l'analyse SHAP	23
1.3.4 Limites du ML dans les États fragiles	23

1.4	De la corrélation à la causalité : le causal machine learning	24
1.4.1	La distinction fondamentale entre prédiction et causalité	24
1.4.2	Les outils d'inférence causale retenus	24
1.5	État de l'art : revue critique des travaux existants	25
1.5.1	Méthodologie de la revue	25
1.5.2	Tableau de synthèse	25
1.5.3	Enseignements de la revue	30
1.6	Conclusion partielle	30
2	Contexte Budgétaire et Institutionnel de la RDC (1996–2023)	32
2.1	Introduction	32
2.2	Le cadre institutionnel du budget national	32
2.2.1	Organisation fonctionnelle	32
2.2.2	La chaîne de la dépense et ses réformes	32
2.2.3	Dépenses courantes et capital : deux logiques	33
2.3	Les quatre régimes macroéconomiques (1996–2023)	33
2.4	La dollarisation et l'effet ciseaux budgétaires	34
2.4.1	Une économie structurellement dollarisée	34
2.4.2	Le mécanisme de l'effet ciseaux	34
2.5	La dépendance aux ressources minières	35
2.6	La gouvernance publique en RDC : entre réformes formelles et réalités organisationnelles	36
2.6.1	Un État sous réformes permanentes	36
2.6.2	Une capacité administrative structurellement hétérogène	36
2.7	L'aide extérieure et le financement des investissements publics	37
2.7.1	Une dépendance structurelle aux partenaires extérieurs	37
2.7.2	Les effets de la fragmentation sur l'exécution budgétaire	37
2.8	Synthèse : implications pour la démarche empirique	38
2.9	Conclusion partielle	39
3	Données et Méthodologie	40
3.1	Introduction	40
3.2	Vue d'ensemble : le pipeline de construction	40
3.3	Sources primaires : les rapports annuels BCC	40
3.3.1	Indisponibilité dans les bases internationales	40
3.3.2	Défis d'extraction et procédure de réparation	42
3.3.3	Harmonisation des dénominations ministérielles	42
3.4	Sources secondaires et variables macroéconomiques	42
3.5	Variables du dataset	44
3.5.1	Variables dépendantes	44
3.5.2	Variables de traitement (DML)	44
3.5.3	Variables confondeurs (contrôles)	46
3.5.4	Variables dérivées par ingénierie	46

3.5.5 Dictionnaire synthétique des 26 variables	47
3.6 Validation et qualité des données	48
3.6.1 Cohérence des séries sur les périodes chevauchantes	48
3.6.2 Tests de cohérence interne	49
3.6.3 Gestion des données manquantes	49
3.6.4 Limites reconnues	50
3.7 Le panel de validation externe : Angola	51
3.8 Pipeline analytique : prédire, classer, interpréter, causer	52
3.9 ML01 : prédire les taux d'exécution	52
3.9.1 Pourquoi trois modèles?	52
3.9.2 Évaluation temporelle	53
3.10 ML02 : classer les régimes d'exécution	53
3.11 ML03 : formaliser les hypothèses causales et interpréter les prédictions	53
3.11.1 Le DAG	53
3.11.2 SHAP	54
3.12 ML04 : Double Machine Learning	55
3.12.1 Modèle partiellement linéaire	55
3.12.2 Pourquoi le DML plutôt qu'une régression classique?	55
3.12.3 Les trois étapes de l'estimateur DML	55
3.12.4 Erreurs standard et stabilité	56
3.12.5 Gestion des données manquantes et fenêtre temporelle	56
3.13 ML05 : Causal Forest pour l'hétérogénéité et la validation	57
3.13.1 Pourquoi la Causal Forest en complément du DML?	57
3.13.2 Double rôle dans le pipeline	57
3.14 Récapitulatif des choix	58
3.14.1 Reproductibilité	58
3.15 Conclusion partielle	59
4 Résultats et Discussion	60
4.1 Introduction	60
4.2 ML01 : Performances prédictives	60
4.2.1 Dépenses courantes	60
4.2.2 Dépenses en capital	61
4.3 ML02 : Classification des régimes d'exécution	61
4.4 ML03 : Analyse SHAP et structure des prédictions	64
4.5 ML04 : Mécanismes causaux – Dépenses courantes	66
4.5.1 C1 : Persistance administrative ($\hat{\theta} = +0,488$, FDR < 1 %)	66
4.5.2 C2 : Effet ciseaux budgétaires ($\hat{\theta} = -0,239$, FDR < 1 %)	67
4.6 ML04 : Mécanismes causaux – Dépenses en capital	67
4.6.1 C3 : Rentes minières ($\hat{\theta} = +0,116$, FDR < 7 %)	68
4.6.2 C4 : Capacité institutionnelle ($\hat{\theta} = +0,115$, FDR < 7 %)	68
4.7 Synthèse des quatre mécanismes causaux	69
4.8 Analyse de robustesse	69

4.8.1 Stabilité sur trois fenêtres temporelles	70
4.8.2 Artefacts nominaux : une mise en garde méthodologique . . .	70
4.9 ML05 : Hétérogénéité des effets par Causal Forest	71
4.10 Validation externe : Angola (2011–2022)	72
4.10.1 Résultats prédictifs	72
4.10.2 Comparaison des mécanismes causaux	72
4.11 Limites de l'approche causale	73
4.12 Synthèse générale des résultats	74
4.13 Conclusion partielle	75
Conclusion générale	77
1. Synthèse des contributions	77
2. Implications	78
2.1 Implications scientifiques	78
2.2 Implications pratiques	78
3. Recommandations	79
4. Perspectives de recherche	79
Bibliographie	81
A Liste des 28 fonctions budgétaires harmonisées	86
B Synthèse globale du pipeline ML	88
C Dashboard interactif Streamlit	90

Introduction Générale

1. Contexte et motivation

Dans les pays à faibles revenus, l'exécution budgétaire est souvent réduite à un simple écart entre le budget approuvé et les dépenses réelles. Cette approche est analytiquement insuffisante. Elle décrit un déséquilibre sans en identifier les causes. Elle n'explique pas non plus pourquoi les taux d'exécution varient fortement d'un secteur à l'autre. La question fondamentale est la suivante : pourquoi un ministère n'utilise que 30 % de ses crédits quand un autre en dépense 120 % ? Ce problème est analytique. Il dépasse la seule dimension gestionnaire.

La RDC illustre cette problématique de façon extrême. Entre 1996 et 2023, le pays a traversé deux conflits armés, plusieurs changements de gouvernance, une hyperinflation culminant à 514 % en 2000 et des cycles miniers très volatils. Les taux d'exécution budgétaire parmi les 28 fonctions analysées oscillent entre 0 et 300 %. Un cadre analytique capable d'identifier des mécanismes causaux robustes sur ces données sera *a fortiori* applicable à des contextes mieux documentés.

L'intelligence artificielle offre aujourd'hui des outils adaptés à ce type de situation. Les méthodes d'ensemble comme Random Forest et XGBoost surpassent les modèles linéaires classiques pour détecter des relations non linéaires dans des données macroéconomiques [10, 15]. L'analyse SHAP permet d'expliquer les prédictions d'un modèle à des décideurs non spécialistes [27]. Le Double Machine Learning a été conçu pour l'inférence causale dans des environnements à forte multicolinéarité [16]. Ce mémoire articule ces trois outils autour d'un objectif unique : prédire, interpréter, puis identifier les causes.

C'est dans ce contexte que s'inscrit la problématique développée dans la section suivante, qui précise les deux lacunes (géographique et conceptuelle) auxquelles ce travail entend répondre.

2. Problématique

Deux problèmes distincts ont orienté ce travail.

Le premier est **géographique**. Les applications du machine learning aux finances publiques se concentrent sur des pays à données régulières et bien documentées [14, 19]. Dans les États fragiles, les données sont incomplètes, les classifications changent dans le temps et les chocs macroéconomiques perturbent brutalement les dynamiques budgétaires [22, 37]. Ce sont précisément ces contextes où l'IA ajouterait le plus de valeur.

Le second est **conceptuel**. La plupart des travaux qui appliquent le ML aux données fiscales traitent prédiction et identification causale comme des exercices équivalents. Ils ne le sont pas. Une variable peut améliorer la précision d'un modèle sans constituer un levier sur lequel une réforme peut agir [4]. Fonder une politique budgétaire sur les seuls résultats prédictifs revient à cibler les mauvaises variables.

La problématique centrale est la suivante :

Comment articuler les méthodes de machine learning et de causal machine learning pour analyser l'exécution des dépenses publiques en RDC, en distinguant les régularités prédictives des mécanismes causaux actionnables, dans un contexte de fragilité institutionnelle, d'hyperinflation historique et de dépendance aux ressources naturelles ?

Cette problématique se décline en cinq questions de recherche opérationnelles, présentées dans la section suivante, qui structurent l'organisation empirique du travail.

3. Questions de recherche

1. Dans quelle mesure les modèles de machine learning permettent-ils de prédire les taux d'exécution budgétaire en RDC, et cette prédictibilité diffère-t-elle entre dépenses courantes et dépenses en capital ?
2. Un système de classification fondé sur des données agrégées peut-il identifier de façon fiable les fonctions à risque de sous-exécution avant la fin de l'année fiscale ?
3. Les variables les plus importantes pour la prédiction coïncident-elles avec les variables causalement déterminantes ?
4. Quels mécanismes macroéconomiques et institutionnels exercent un effet causal identifiable sur l'exécution des dépenses, et ces mécanismes diffèrent-ils entre dépenses courantes et en capital ?
5. Les résultats obtenus en RDC sont-ils reproductibles sur un autre État fragile dépendant des ressources naturelles, comme l'Angola ?

Ces cinq questions structurent le mémoire selon une logique cumulative : les deux premières portent sur la prévisibilité, la troisième sur la comparaison entre prédiction et causalité, la quatrième sur l'identification des mécanismes, et la cinquième sur la validité externe. Les hypothèses formulées dans la section suivante précisent les réponses attendues à chacune d'elles.

4. Hypothèses de recherche

Cinq hypothèses guident cette analyse. Elles sont fondées sur la littérature existante et sur les caractéristiques connues du contexte congolais. Elles ne constituent

pas des certitudes mais des attentes théoriquement justifiées.

- H1.** Les dépenses courantes, qui couvrent les salaires et les charges récurrentes, suivent une logique de reconduction annuelle. On s'attend donc à ce qu'elles soient plus prévisibles que les dépenses en capital, dont le niveau dépend largement de facteurs extérieurs au système budgétaire formel.
- H2.** Les relations entre variables budgétaires congolaises étant marquées par des non-linéarités structurelles, des ruptures de série et des effets de seuil, les algorithmes d'apprentissage par ensemble (Random Forest, XGBoost) produiront des performances prédictives supérieures à celles d'un modèle linéaire pénalisé (Ridge) sur le même panel.
- H3.** Le classement des variables par importance prédictive (SHAP) et leur classement par effet causal estimé (Double Machine Learning) divergent systématiquement. Cette divergence s'explique par le fait que certaines variables à fort pouvoir discriminant statistique, comme le taux d'exécution de l'exercice précédent, reflètent des régularités historiques non actionnables par voie de politique publique. La prédiction et l'identification causale constituent ainsi deux analyses complémentaires mais non substituables.
- H4.** L'exécution des dépenses courantes est principalement déterminée par deux mécanismes causaux. Le premier est la persistance des capacités administratives : un ministère disposant des équipes et des procédures en place maintient d'une année sur l'autre son niveau d'exécution, indépendamment des décisions d'allocation. Le second est l'érosion monétaire : la dépréciation du franc congolais en cours d'exercice réduit la valeur réelle des crédits votés en début d'année, affectant particulièrement les lignes budgétaires à forte composante d'importation.
- H5.** L'exécution des dépenses en capital obéit à une logique structurellement distincte. Le financement des projets d'investissement public dépend de manière procyclique des recettes minières : une hausse des cours des matières premières libère des ressources qui permettent la relance de projets différés, tandis qu'une contraction de la rente provoque leur gel. La capacité institutionnelle d'absorption constitue une contrainte symétrique : en deçà d'un seuil de gouvernance, l'augmentation des allocations budgétaires ne se traduit pas mécaniquement en dépenses réalisées.

Ces cinq hypothèses sont testées dans les chapitres 3 et 4 selon un protocole rigoureux de validation croisée temporelle et d'inférence causale. La section suivante précise les objectifs concrets qui découlent de cette architecture hypothétique.

5. Objectifs

L'objectif général de ce travail est de développer un cadre analytique combinant prédiction et causalité pour analyser l'exécution des dépenses publiques en RDC sur

la période 1996–2023.

La première étape, la plus contraignante, a été la construction du jeu de données. Les données d'exécution fonctionnelle pour la RDC n'existent dans aucune base internationale. Il a donc fallu les extraire des rapports annuels de la Banque Centrale du Congo, les nettoyer, puis harmoniser les dénominations ministérielles sur 28 ans malgré les réorganisations répétées du gouvernement.

Une fois le panel disponible, la première question empirique a porté sur la prévisibilité des taux d'exécution avant la fin de l'année fiscale. Trois modèles ont été comparés : Ridge, Random Forest et XGBoost. La validation croisée temporelle adoptée évite toute fuite d'information vers le passé.

La seconde question était plus fondamentale. Les variables qui prédisent bien sont-elles aussi celles qui causent les écarts d'exécution ? L'analyse SHAP a permis d'interpréter les prédictions. Le Double Machine Learning a estimé des effets causaux nets des confondeurs. La Causal Forest a ensuite vérifié si ces effets varient entre types de ministères.

Enfin, pour tester la généralisation des mécanismes identifiés, le pipeline a été répliqué sur un panel angolais (2011–2022). L'Angola partage plusieurs caractéristiques structurelles avec la RDC mais sa ressource principale est le pétrole, non les minerais solides.

La réalisation de ces objectifs repose sur une démarche méthodologique structurée en quatre étapes, décrite dans la section suivante.

6. Démarche méthodologique

La démarche s'articule autour d'un pipeline séquentiel en quatre composantes.

ML 01 : Prédiction. Des modèles supervisés (Ridge, Random Forest, XGBoost) prédisent les taux d'exécution des dépenses courantes et en capital, évalués par validation croisée temporelle (GroupKFold par année, [9]).

ML 02 : Classification. Un classifieur Random Forest identifie les régimes d'exécution (sous-exécution, normale, sur-exécution), avec une attention particulière au rappel sur la classe de sous-exécution, qui est la plus critique sur le plan opérationnel.

ML 03 : DAG et SHAP. Un Graphe Acyclique Dirigé formalise explicitement les hypothèses structurelles causales : traitements, confondeurs, résultats, avant toute estimation. L'analyse SHAP interprète les contributions prédictives et révèle le décalage entre importance prédictive et pertinence causale.

ML 04 : Double Machine Learning et Causal Forest. Le DML estime les effets causaux moyens de neuf traitements via cross-fitting et erreurs standard clusterisées par année. La Causal Forest explore l'hétérogénéité des effets et valide les estimations DML. Le pipeline est ensuite répliqué sur l'Angola pour la validation externe.

Les données primaires proviennent de trois rapports annuels de la Banque

Centrale du Congo (2005, 2014, 2023), consolidés en un panel de 784 observations couvrant 28 fonctions budgétaires sur 28 ans, complétés par les sources IMF WEO et Banque mondiale WDI/WGI.

Cette démarche, fondée sur des données primaires et un pipeline analytique original, produit des contributions distinctes à trois niveaux, présentées dans la section suivante.

7. Contribution de l'étude

Ce travail apporte trois contributions distinctes.

Sur le plan empirique, le mémoire constitue un panel original de 784 observations couvrant 28 fonctions budgétaires sur 28 ans. Ces données n'existaient dans aucune base internationale. Quatre mécanismes causaux sont identifiés : la persistance administrative, l'effet ciseaux lié au taux de change, les rentes minières et la capacité institutionnelle. La littérature les associait sans les démontrer causalement.

Sur le plan méthodologique, le pipeline relie prédiction (ML01, ML02), interprétabilité (ML03) et inférence causale (ML04, ML05). À notre connaissance, c'est la première application du Double Machine Learning à l'exécution budgétaire dans un État africain fragile [31].

Sur le plan opérationnel, un classificateur d'alerte précoce atteint un rappel de 83 % sur la classe de sous-exécution. Concrètement, cinq ministères en difficulté sur six sont détectés avant la fin de l'exercice. Cet outil est déployable sans compétences particulières en apprentissage automatique.

Ces contributions ont été développées dans le cadre du Laboratoire ABIL, structure d'accueil scientifique de ce mémoire, dont la présentation constitue l'objet de la section suivante.

8. Cadre institutionnel d'accueil

Ce mémoire a été réalisé au sein du Laboratoire ABIL (Artificial intelligence, Big data and modeLing simulation), laboratoire de recherche de la Faculté des Sciences de l'Université de Kinshasa (UNIKIN). Fondé le 17 mars 2014, ABIL se consacre au développement et à l'application de méthodes d'intelligence artificielle, d'analyse de données massives et de simulation pour répondre à des questions scientifiques ancrées dans les réalités africaines. Il est partenaire des universités de Lubumbashi (UNILU) et de Kisangani (UNIKIS), avec lesquelles il développe des activités de formation et de recherche conjointes.

Le laboratoire est structuré autour de trois instances : une Assemblée Générale réunissant l'ensemble des membres, un Conseil Scientifique chargé de l'orientation des axes de recherche, et un Conseil de Gestion responsable de l'administration courante. La direction scientifique et la gestion opérationnelle sont assurées par un Bureau Exécutif dont la composition est indiquée dans le tableau suivant.

TABLE 2 – Bureau Exécutif du Laboratoire ABIL

Fonction	Titulaire
Directeur	Prof. Kasoro Mulenda Nathanael
Directeur Adjoint	Prof. Mabela Makengo Rostin
Secrétaire	Prof. Selain Kasereka Kabunga

Le présent mémoire a bénéficié de la direction scientifique du Prof. Selain Kasereka Kabunga (Secrétaire d'ABIL) et de la co-direction du Prof. Kasoro Mulenda Nathanaël (Directeur d'ABIL). Il s'inscrit dans l'axe de recherche consacré à l'application des méthodes d'apprentissage automatique aux données socioéconomiques des pays en développement. Des informations complémentaires sur les activités et les publications du laboratoire sont disponibles à l'adresse <https://abil.ac.cd/>.

La section suivante présente l'organisation générale du mémoire en quatre chapitres.

9. Structure du mémoire

Ce mémoire est organisé en quatre chapitres qui suivent la logique du pipeline analytique. Le **Chapitre 1** présente le cadre théorique et la revue de littérature, couvrant l'exécution budgétaire comme objet d'analyse, l'apprentissage automatique en économie publique, et la distinction fondamentale entre prédiction et causalité. Le **Chapitre 2** décrit le contexte budgétaire et institutionnel de la RDC sur la période 1996–2023 : les quatre régimes macroéconomiques, la dollarisation, la dépendance aux ressources minières et le rôle de l'aide extérieure. Le **Chapitre 3** constitue le cœur méthodologique du travail : il présente à la fois la construction du panel de 784 observations à partir des rapports BCC, et l'ensemble du pipeline analytique ML01–ML05, du DAG aux estimations DML et Causal Forest. Le **Chapitre 4** présente les résultats empiriques pour la RDC et la validation externe sur l'Angola. Enfin, la **Conclusion générale** synthétise les quatre mécanismes causaux identifiés, discute leurs implications pour la politique publique congolaise, reconnaît les limites de l'analyse et ouvre sur les perspectives de recherche.

CADRE THÉORIQUE ET ETAT DE L'ART

1.1 Introduction

Ce chapitre établit les bases théoriques et l'état de l'art sur lesquels repose l'analyse empirique. La Section 1.2 définit l'exécution budgétaire et ses déterminants dans les pays à faible revenu. La Section 1.3 présente les méthodes d'apprentissage automatique retenues et justifie leur adéquation aux données macro-fiscales fragmentaires. La Section 1.4 expose la distinction entre prédiction et causalité, et introduit les outils correspondants : DAG, DML, Causal Forest. La Section 1.5 positionne enfin ce travail par rapport à la littérature existante.

1.2 L'exécution budgétaire comme objet d'analyse

1.2.1 Définition et enjeux conceptuels

L'exécution budgétaire désigne le processus par lequel les crédits votés se transforment, ou non, en dépenses effectives. Elle constitue le maillon central de la chaîne de la dépense publique : entre la planification en amont et l'évaluation des politiques en aval. Un budget bien conçu mais mal exécuté produit les mêmes effets qu'un budget insuffisant du point de vue de la prestation de services [1].

On distingue classiquement deux types de dépenses publiques. Les **dépenses courantes** (ou dépenses de fonctionnement) couvrent les charges récurrentes de l'État : salaires des fonctionnaires, carburant, fournitures, loyers, entretien courant. Elles répondent à une logique d'inertie administrative : les engagements pris une année ont tendance à se reconduire l'année suivante, ce qui produit une relative régularité des taux d'exécution. Les **dépenses en capital** (ou dépenses d'investissement) concernent la réalisation d'infrastructures, l'acquisition d'équipements durables et le financement de projets de développement. Elles dépendent davantage de conditions externes : disponibilité des financements, capacité de passation de marchés, prix des matériaux et sont par nature plus volatiles et moins prévisibles [17].

Le taux d'exécution budgétaire est défini comme le rapport entre les dépenses réalisées et les crédits initialement approuvés, exprimé en pourcentage. L'Équation (1.1) formalise cette définition :

$$\text{Taux d'exécution}_{it} = \frac{\text{Dépenses réalisées}_{it}}{\text{Crédits approuvés}_{it}} \times 100 \quad (1.1)$$

où i indexe la fonction budgétaire et t l'année fiscale. Un taux inférieur à 100 % signale une *sous-exécution*, qui peut refléter des blocages administratifs, des contraintes de trésorerie ou des défaillances de la chaîne de la dépense. Un taux supérieur à 100 % indique une *sur-exécution*, généralement liée à des budgets rectificatifs en cours d'année ou à des dépenses extrabudgétaires [17].

1.2.2 Les déterminants de l'exécution budgétaire dans les pays à faible revenu

Trois facteurs expliquent systématiquement les écarts d'exécution dans la littérature, indépendamment du pays étudié.

Le premier est la **capacité institutionnelle**. Elle recouvre la qualité des procédures de passation de marchés, la compétence des agents de liquidation, la fiabilité des systèmes d'information budgétaire et la continuité des équipes. Un ministère doté de ces capacités transforme régulièrement ses crédits en dépenses. À l'inverse, des procédures défaillantes peuvent bloquer une demande de paiement pendant plusieurs mois [1]. Les indicateurs WGI restent trop agrégés pour capturer ces différences au niveau ministériel.

Le second est la **dépendance aux ressources naturelles**. Dans les pays exportateurs de matières premières, les recettes budgétaires sont fortement corrélées aux prix mondiaux des hydrocarbures ou des minerais. Les cycles *boom-bust* créent une volatilité des ressources disponibles qui se répercute directement sur les dépenses en capital : les windfalls débloquent des projets d'investissement qui restent ensuite gelés lors des phases de contraction [17].

Le troisième est la **pression politique**. Les cycles électoraux peuvent induire des sur-exécutions en période préélectorale, notamment sur les dépenses courantes et les transferts sociaux. À l'inverse, les changements de gouvernement introduisent des ruptures dans les priorités sectorielles qui perturbent l'exécution des budgets d'investissement déjà engagés [17].

À ces trois facteurs s'ajoute, dans les contextes très dollarisés comme la RDC, l'effet du **taux de change**. Lorsque les crédits sont votés en monnaie locale contre un taux de change projeté, une dépréciation en cours d'année érode mécaniquement le pouvoir d'achat réel des allocations. Ce mécanisme, appelé *effet ciseaux budgétaires*, est rarement formalisé dans la littérature, mais constitue l'un des principaux résultats empiriques de ce mémoire.

1.2.3 Limites des approches économétriques classiques

La plupart des études empiriques reposent sur des régressions en panel avec effets fixes [17, 36]. Ces approches présentent trois limites dans le contexte congolais.

La première est la non-linéarité. Les modèles à coefficients constants supposent une relation stable entre les variables explicatives et le taux d'exécution. Quatre régimes macroéconomiques très différents se sont succédé en RDC entre

1996 et 2023. Ce qui explique l'exécution sous un régime ne l'explique pas nécessairement sous un autre.

La deuxième est la multicollinéarité. Le PIB, les recettes fiscales, la dette et le taux de change évoluent ensemble en RDC, portés par les mêmes cycles miniers. Les régressions OLS produisent alors des coefficients instables et difficilement interprétables [16].

La troisième est la gestion des ruptures structurelles. Deux guerres, une hyperinflation et un choc pandémique ont créé des régimes si différents que les estimateurs standard ne peuvent les traiter correctement sans contrôles explicites par période. Ces trois limites justifient le recours au machine learning pour la prédiction et au Double Machine Learning pour l'inférence causale.

1.3 L'apprentissage automatique en économie publique

1.3.1 Principes généraux

L'apprentissage automatique (machine learning, ML) regroupe un ensemble de méthodes statistiques capables d'apprendre des structures complexes à partir des données, sans que les relations fonctionnelles soient explicitement spécifiées par le chercheur. Contrairement à l'économétrie traditionnelle, dont l'objectif premier est l'identification de paramètres structurels interprétables, le ML vise initialement la minimisation de l'erreur de prédiction hors échantillon.

En économie publique, les applications du ML se répartissent en trois grandes catégories : la **prédiction fiscale** (prévision des recettes et dépenses, détection précoce des déséquilibres) [14] ; la **détection d'anomalies** dans les transactions de dépenses à des fins d'audit [19] ; et la **classification du risque** budgétaire de ministères, projets ou fournisseurs [32].

1.3.2 Les méthodes d'ensemble : Random Forest et XGBoost

Parmi les algorithmes de ML supervisé, les *méthodes d'ensemble* se sont imposées comme les plus performantes pour les données tabulaires macroéconomiques.

Le **Random Forest** [10] repose sur l'agrégation de centaines d'arbres de décision. Chaque arbre est entraîné sur un sous-échantillon tiré avec remise. À chaque nœud, seul un sous-ensemble de variables est considéré, ce qui force la diversité entre arbres. Les prédictions sont ensuite moyennées. Ce mécanisme réduit la variance et limite le surapprentissage, comme le formalise l'Équation (1.2) :

$$\hat{y}_{\text{RF}}(\mathbf{x}) = \frac{1}{B} \sum_{b=1}^B T_b(\mathbf{x}) \quad (1.2)$$

où B est le nombre d'arbres et $T_b(\mathbf{x})$ la prédiction du b -ième arbre pour l'observation $\mathbf{x}$.

XGBoost [15] repose sur une logique différente : le *gradient boosting*. Les arbres sont construits séquentiellement, chaque nouvel arbre corrigeant les erreurs résiduelles du modèle précédent. La régularisation intégrée (L_1 et L_2 sur les poids des feuilles) contrôle le surajustement. Ces deux méthodes sont comparées à une régression Ridge, modèle linéaire pénalisé servant de référence, dont le critère de minimisation est donné par l'Équation (1.3) :

$$\hat{\beta} = \arg \min_{\beta} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \beta)^2 + \alpha \|\beta\|_2^2 \quad (1.3)$$

La comparaison entre ces trois modèles permet de quantifier le gain apporté par la non-linéarité dans l'analyse de l'exécution budgétaire.

1.3.3 L'explicabilité : l'analyse SHAP

Les modèles d'ensemble sont souvent critiqués pour leur caractère de *boîte noire* : leurs prédictions sont précises, mais difficiles à interpréter. Ce reproche est particulièrement problématique en politique publique, où l'interprétation est aussi importante que la précision [3].

L'analyse **SHAP** (*SHapley Additive exPlanations*) [27] résout ce problème en décomposant la prédiction de chaque observation en contributions individuelles des variables, fondées sur la théorie des jeux coopératifs (valeurs de Shapley), comme l'exprime l'Équation (1.4) :

$$\hat{f}(\mathbf{x}_i) = \phi_0 + \sum_{j=1}^p \phi_j(i) \quad (1.4)$$

où ϕ_0 est la prédiction de base et $\phi_j(i)$ la contribution de la variable j à la prédiction pour l'observation i . L'importance globale d'une variable est mesurée par $|\bar{\phi}_j| = \frac{1}{n} \sum_{i=1}^n |\phi_j(i)|$.

Un résultat central de cette analyse illustre la limite de SHAP. Le taux de change représente le deuxième mécanisme causal le plus fort sur les dépenses courantes selon le DML. Pourtant, il est quasi absent du classement SHAP. La raison est structurelle : le franc congolais se déprécie chaque année et affecte tous les ministères simultanément dans la même direction. Un algorithme qui apprend des différences transversales entre observations ne peut pas détecter un signal à variation temporelle pure. C'est précisément pour dépasser cette limite que l'inférence causale est mobilisée.

1.3.4 Limites du ML dans les États fragiles

Malgré leurs performances, les méthodes de ML présentent plusieurs limites spécifiques aux contextes de fragilité institutionnelle [9, 30]. La disponibilité des

données est la contrainte la plus immédiate : dans la plupart des États fragiles, les données administratives sont incomplètes ou non numérisées, le taux de données manquantes sur les dépenses en capital en RDC (40,6 %) en est une illustration directe. La stabilité temporelle des modèles est également problématique dans des environnements marqués par des ruptures structurelles. Enfin, et c'est la limite analytique la plus importante, le ML prédit sans expliquer causalement [4] : un modèle qui prédit bien ne dit rien sur l'effet d'une intervention sur la variable cible. C'est ce vide que comble le causal machine learning [3, 26].

1.4 De la corrélation à la causalité : le causal machine learning

1.4.1 La distinction fondamentale entre prédiction et causalité

Un modèle prédictif cherche à estimer $\mathbb{E}[Y \mid X]$, l'espérance de la variable d'intérêt conditionnellement aux variables observées. Toute variable corrélée avec Y est potentiellement utile, qu'elle en soit ou non la cause. Un modèle causal cherche à estimer l'effet d'une intervention : $\mathbb{E}[Y \mid \text{do}(T = t)]$, ce que deviendrait Y si l'on forçait la variable de traitement T à prendre la valeur t , indépendamment de ses déterminants habituels [33].

Cette distinction a des implications directes pour la réforme budgétaire. Un ministère qui a bien exécuté l'année passée a de fortes chances de le faire encore cette année. Mais la cause n'est pas le chiffre passé en lui-même : c'est la capacité institutionnelle accumulée. Intervenir sur le taux d'exécution historique ne change rien. Seule une analyse causale permet de répondre à la question pertinente pour un décideur : que se passerait-il si l'on agissait sur cette variable ?

1.4.2 Les outils d'inférence causale retenus

Cette distinction entre prédiction et causalité nous a amenés à chercher des outils adaptés au contexte congolais, où les variables budgétaires, monétaires et institutionnelles évoluent souvent ensemble, rendant difficile l'isolement de l'effet propre de chacune.

Les Graphes Acycliques Dirigés (DAG) nous ont permis d'établir explicitement les relations supposées entre variables avant toute estimation. Le Double Machine Learning [16] a été retenu parce qu'il sépare ces effets même quand les données sont complexes. La Causal Forest [36] nous a permis d'aller plus loin en vérifiant si un effet moyen cache des réalités très différentes selon le ministère ou la période. Ces trois outils sont présentés en détail dans le Chapitre suivant.

1.5 État de l'art : revue critique des travaux existants

1.5.1 Méthodologie de la revue

La revue présentée ici couvre les travaux empiriques publiés entre 2011 et 2025 à l'intersection de trois champs : le machine learning appliqué aux finances publiques, l'inférence causale par ML, et les déterminants de l'exécution budgétaire dans les pays à faible revenu et les États fragiles. Les travaux ont été sélectionnés sur la base de leur pertinence méthodologique ou empirique par rapport à la problématique de ce mémoire. Le Tableau 1.1 présente une synthèse critique de onze contributions représentatives, classées par thème.

1.5.2 Tableau de synthèse

Le Tableau 1.1 ci-après rassemble onze contributions représentatives de la littérature, organisées selon trois axes thématiques : les travaux sur l'exécution budgétaire dans les pays en développement, les applications du machine learning à l'économie publique, et les approches d'inférence causale appliquées aux données de politique budgétaire. Pour chaque travail, le tableau précise le problème traité, les algorithmes mobilisés, les points forts méthodologiques et les limites relevées. Ce positionnement comparatif permet d'identifier les deux lacunes auxquelles ce mémoire entend répondre : l'absence d'application à un État africain fragile et l'absence de distinction systématique entre prédiction et causalité.

TABLE 1.1 – État de l’art et Revue critique des travaux existants

N°	Nom de l’Article / Auteurs	Problème traité	Algorithmes	Points forts	Points faibles
1. Machine learning prédictif en finances publiques					
1	<i>Exploratory data analysis for financial accounting using ML</i> Chakri et al. (2023) <i>Decision Analytics Journal</i>	Détection d’anomalies comptables et prédiction de données financières agrégées au Maroc	RF, régression logistique, k-means	Comparaison multi-algorithmes rigoureuse ; données réelles de gestion publique	Contexte LMIC stable ; pas de désagrégation fonctionnelle ; aucune dimension causale
2	<i>AI-based analysis of change in public finance</i> Panda (2024) <i>IEEE IC2PCT</i>	Analyse comparative des structures de finances publiques entre l’Inde et les marchés internationaux	Réseaux de neurones, RF	Mise en évidence des divergences structurelles inter-pays	Niveau très agrégé ; pas d’exécution fonctionnelle ; État institutionnellement stable
3	<i>AI for Public Expenditure Analysis in LICs</i> Nzazi et al. (2025) <i>Procedia Computer Science, Vol. 272</i>	Revue systématique des applications de l’IA à l’analyse des dépenses publiques dans les PFR	Revue (RF, XGB, SHAP)	Premier état de l’art centré sur les PFR ; identification des lacunes géographiques ; base directe du présent mémoire	Pas d’estimation empirique propre ; données primaires non mobilisées
Suite page suivante					

Tableau 1.1 (suite)

N°	Nom de l'Article / Auteurs	Problème traité	Algorithmes	Points forts	Points faibles
4	<i>AI integration in financial services</i> Vuković et al. (2025) <i>Humanities & Social Sciences Comm.</i>	Revue sur l'IA dans les services financiers et défis réglementaires	Revue (deep learning, NLP, RF)	Couverture des tendances réglementaires ; analyse des risques liés à l'IA	Centré sur le secteur privé ; peu applicable aux États fragiles
2. Inférence causale et Double Machine Learning					
5	<i>Double/debiased ML for treatment and structural parameters</i> Chernozhukov et al. (2018) <i>The Econometrics Journal</i>	Estimation causale dans des environnements à haute dimension avec confondeurs nombreux et multicolinéarité élevée	DML (RF et Lasso comme nuisance)	Fondement théorique rigoureux ; estimateur $\sqrt{n}$ -consistant sans instrument	Nécessite un grand n ; pas d'application aux finances publiques des États fragiles
6	<i>Machine learning estimation of heterogeneous causal effects</i> Knaus (2021) <i>The Econometrics Journal</i>	Évaluation de programmes d'emploi en Europe avec effets hétérogènes par causal ML	DML, CF, méta-learners	Comparaison systématique des estimateurs causaux ML ; traitement de l'hétérogénéité des effets	Contexte de pays riche ; données administratives complètes
Suite page suivante					

Tableau 1.1 (suite)

N°	Nom de l'Article / Auteurs	Problème traité	Algorithmes	Points forts	Points faibles
7	<i>The value added of ML to causal inference</i> Baibaldi & Naghi (2024) <i>The Econometrics Journal</i>	Méta-analyse de l'apport du ML à l'inférence causale par réplication d'études empiriques classiques	DML, CF, IV augmenté ML	Démonstration empirique rigoureuse du gain du ML sur les approches paramétriques	Ne couvre pas les finances publiques ni les États fragiles
3. Exécution budgétaire dans les États fragiles					
8	<i>The Limits of Institutional Reform in Development</i> Andrews (2013) <i>Cambridge University Press</i>	Contraintes institutionnelles sur l'exécution des dépenses publiques dans les États fragiles	Étude de cas, analyse qualitative	Cadre conceptuel de référence ; couverture large d'États fragiles	Pas de ML ni de causalité ; données agrégées ; pas de désagrégation fonctionnelle
9	<i>Public Investment Management Bottlenecks in LICs</i> Eltokhy et al. (2024) <i>IMF Working Paper</i>	Identification des goulots d'étranglement dans la gestion de l'investissement public dans les PFR	OLS, effets fixes	Données IMF sur large panel de PFR ; bottlenecks institutionnels identifiés	Approche linéaire uniquement ; pas de ML ni de causalité ; désagrégation insuffisante
Suite page suivante					

Tableau 1.1 (suite)

N°	Nom de l'Article / Auteurs	Problème traité	Algorithmes	Points forts	Points faibles
10	<i>IMF-supported programs in low-income countries : Fragile versus non-fragile states</i> Cai, K., Martin, É., & Várdy, F. (2024) <i>IMF Working Paper WP/24/221</i>	Analyse comparative de l'exécution budgétaire et de la capacité institutionnelle dans les États fragiles et non-fragiles sous programme FMI sur panel africain	OLS, effets fixes, comparaisons panel	Large panel IMF ; distinction États fragiles / non-fragiles rigoureuse ; identification du rôle de la capacité d'absorption	Approche linéaire uniquement ; pas de ML ni de causalité ; désagrégation fonctionnelle absente
Abréviations : PFR = Pays à faible revenu ; DML = Double Machine Learning ; RF = Random Forest ; XGB = XGBoost ; SHAP = SHapley Additive exPlanations ; CF = Causal Forest ; DAG = Graphe Acyclique Dirigé ; NLP = Natural Language Processing ; IV = Variables instrumentales ; OLS = Moindres carrés ordinaires ; RDC = République Démocratique du Congo.					

1.5.3 Enseignements de la revue

Trois constats se dégagent de cette revue.

Le premier est géographique. Les méthodes d'ensemble sont performantes sur des données financières complexes. Mais leur application concerne quasi exclusivement des pays à revenu intermédiaire ou élevé (N° 1, 2, 4, 5). Les États fragiles restent absents de la littérature empirique. La revue de Nzazi et al. (2025, N° 3) est la première à documenter ce vide de façon systématique.

Le deuxième constat porte sur la causalité. Les applications du DML en économie du travail (N° 6, 7) démontrent qu'il est possible d'identifier des effets causaux sans instrument, même en haute dimension. Aucun de ces travaux ne porte sur l'exécution budgétaire dans un État africain fragile. Ce vide est la lacune que ce mémoire cherche à combler.

Le troisième constat concerne les travaux sur les États fragiles (N° 9, 10). Ils posent de bonnes questions et proposent des cadres conceptuels utiles. Leurs données restent cependant agrégées et leurs estimateurs linéaires. Ils ne peuvent capturer ni les non-linéarités ni les effets causaux individuels. Aucun ne dispose de données d'exécution fonctionnelle pour la RDC sur 28 ans. Ces trois lacunes fondent les hypothèses H1 à H5 formulées en introduction.

1.6 Conclusion partielle

Ce chapitre a établi trois fondements sans lesquels les résultats du Chapitre 4 seraient difficiles à interpréter.

Premier fondement : l'exécution budgétaire est un phénomène multidimensionnel. Elle ne se réduit pas à un écart entre crédits votés et dépenses réalisées. Elle reflète des équilibres institutionnels, monétaires et politiques profonds, qui varient selon le type de dépense, la fonction budgétaire et le régime macroéconomique. Les modèles de régression classique à coefficients constants ne peuvent pas saisir cette hétérogénéité sur un panel aussi contrasté que la RDC 1996–2023.

Deuxième fondement : la distinction entre prédiction et causalité est analytiquement nécessaire. Une variable peut améliorer la précision d'un modèle prédictif sans constituer un levier d'action pour la politique budgétaire. Le lag d'exécution prédit bien l'avenir ; il n'est pas modifiable par une réforme. Le Double Machine Learning a précisément été conçu pour séparer ces deux dimensions dans des environnements à forte multicolinéarité, comme celui que décrit le Chapitre 2.

Troisième fondement : la revue de littérature révèle un vide géographique et méthodologique. Les travaux combinant apprentissage automatique et inférence causale sur des données budgétaires fonctionnelles primaires d'États africains fragiles sont inexistantes. Ce vide justifie à la fois le choix du terrain et le choix des outils.

Le Chapitre 2 exploite ces fondements théoriques pour décrire le contexte empirique congolais. Il montrera comment chacune des quatre grandes caractéristiques

structurelles de la RDC (quatre régimes budgétaires, dollarisation, dépendance minière et fragmentation de la gouvernance) impose des contraintes méthodologiques précises sur le pipeline analytique développé au Chapitre 3.

CONTEXTE BUDGÉTAIRE ET INSTITUTIONNEL DE LA RDC (1996–2023)

2.1 Introduction

Ce chapitre décrit le contexte empirique dans lequel s’inscrit l’analyse. La volatilité et l’hétérogénéité des données congolaises ne sont pas des inconvénients à corriger : elles justifient les choix méthodologiques présentés au Chapitre 3. La Section 2.2 présente le cadre institutionnel du budget national. La Section 2.3 décrit les quatre régimes macroéconomiques de la période 1996–2023. La Section 2.4 analyse la dollarisation et l’effet ciseaux budgétaires. Les Sections 2.5 et 2.6 traitent respectivement des ressources minières et de la gouvernance. La Section 2.7 examine l’aide extérieure. La Section 2.8 tire les implications pour la démarche empirique.

2.2 Le cadre institutionnel du budget national

2.2.1 Organisation fonctionnelle

Le budget congolais est structuré autour de **28 fonctions budgétaires** couvrant les missions régaliennes (Présidence, Défense, Justice), sociales (Éducation, Santé), économiques (Mines, Transports, Travaux publics) et transversales (Finances, Plan). Ces 28 fonctions constituent les unités d’observation du panel de ce mémoire, permettant un suivi comparable sur toute la période malgré les réorganisations ministérielles. Les appropriations suivent le cadre TOFE aligné sur les normes GFS du FMI [12, 21], votées annuellement en francs congolais (CDF). Les *budgets rectificatifs* constituent l’instrument principal d’ajustement en cours d’année.

2.2.2 La chaîne de la dépense et ses réformes

La chaîne de la dépense comprend quatre étapes : engagement, liquidation, ordonnancement et paiement. Les goulets d’étranglement se concentrent aux étapes de liquidation et d’ordonnancement, où les délais peuvent s’étendre sur plusieurs mois [17]. Deux réformes ont tenté de rationaliser ce processus : la **Loi organique de 2011** sur les finances publiques, et le déploiement progressif du **SIGFIP**. Leurs effets restent limités sur les dépenses en capital en raison des bottlenecks de passation de

marchés [17, 22].

2.2.3 Dépenses courantes et capital : deux logiques

Les dépenses courantes suivent la logique de *reconduction* annuelle des salaires, carburant, fournitures, matériels qui produit une relative prévisibilité exploitable par les modèles ML. Par contre les dépenses en capital dépendent de facteurs largement exogènes : financements extérieurs, capacité de passation de marchés, prix des matériaux, bailleurs de fonds. C'est précisément pour cette raison que les modèles du ML peinent sur cette catégorie, comme nous le verrons au Chapitre 4.

2.3 Les quatre régimes macroéconomiques (1996–2023)

Sur 28 ans, la RDC a traversé quatre périodes budgétaires très contrastées, et ce qu'on apprend dans l'une ne marche pas forcément dans l'autre. Le Tableau 2.1 résume ces régimes.

1996–2001 : la guerre et l'inflation. Cette période est la plus difficile à analyser sur le plan économétrique. Deux guerres civiles ont désorganisé l'administration. L'inflation atteint 514 % en 2000. Les taux d'exécution nominaux des dépenses courantes semblent élevés mais reflètent une illusion monétaire : les prix progressent plus vite que les budgets. Cette sous-période est exclue des spécifications préférées du DML.

2002–2010 : la stabilisation macroéconomique. L'accord de Pretoria et l'aide du FMI font refluer l'inflation. Les recettes fiscales passent de moins de 5 % à environ 10 % du PIB. Les dépenses courantes s'établissent entre 60 et 80 %. Les dépenses en capital restent bloquées par l'insuffisance des financements extérieurs.

2011–2019 : le boom minier. Les prix du cobalt et du cuivre progressent fortement. Les projets d'investissement gelés reprennent [37]. Les taux d'exécution en capital atteignent 40 à 80 %. Les dépenses courantes dépassent 100 % dans plusieurs ministères.

2020–2023 : le choc COVID. Les recettes minières s'effondrent. Les dépenses de santé augmentent fortement. Les taux d'exécution deviennent difficiles à interpréter. Des indicateurs de contrôle spécifiques à cette période ont été introduits dans les spécifications DML.

TABLE 2.1 – Les quatre régimes budgétaires de la RDC (1996–2023)

Période	Caractéristiques principales	Exec. C	Exec. K
1996–2001	Conflits armés; hyperinflation (pic 514 %); illusion budgétaire nominale	Élevé (nominal)	Quasi-nul
2002–2010	Stabilisation; reconstruction institutionnelle; premières élections (2006)	60–80 %	20–40 %
2011–2019	Boom cobalt-cuivre; expansion budgétaire; investissements débloqués	80–120 %	40–80 %
2020–2023	Choc COVID; volatilité des recettes; disruption des dépenses en capital	Volatile	Perturbé
Exec. C = taux d'exécution dépenses courantes; Exec. K = taux d'exécution dépenses en capital. Moyennes approximatives par régime; forte hétérogénéité fonctionnelle au sein de chaque période. Source : BCC, rapports annuels 2005, 2014, 2023, [21]; calculs des auteurs.			

2.4 La dollarisation et l'effet ciseaux budgétaires

2.4.1 Une économie structurellement dollarisée

Environ 90 % [21] des dépôts bancaires sont en USD. Les agents économiques contractent et épargnent en dollars, mais l'État vote ses budgets en CDF. Cette dualité monétaire permanente est à l'origine du principal mécanisme de distorsion budgétaire testé causalement dans ce mémoire.

2.4.2 Le mécanisme de l'effet ciseaux

En janvier, le budget est voté en francs congolais sur la base d'un taux de change projeté. Les contrats réels, tels que le carburant, les équipements importés et l'assistance technique, sont libellés en dollars [19]. Lorsque le franc congolais se déprécie, les crédits votés perdent du pouvoir d'achat sans qu'aucune décision de coupe ne soit prise. Un budget de 100 Mds CDF voté à 2 000 CDF/USD ne représente plus que 83 Mds si le taux atteint 2 400 CDF/USD en décembre. C'est une perte de 17 % d'origine monétaire, non administrative.

Ce que les statistiques enregistrent comme une sous-exécution est en réalité une érosion du pouvoir d'achat. Le DML quantifie cet effet causalement : $\hat{\theta} = -0,239$, FDR < 1 %.

La Figure 2.1 illustre ce mécanisme de transmission de la dépréciation du franc congolais vers la sous-exécution apparente des dépenses.




FIGURE 2.1 – L’effet ciseaux budgétaires en RDC : mécanisme de transmission de la dépréciation du CDF vers la sous-exécution des dépenses (mécanisme causal C2).

2.5 La dépendance aux ressources minières

Le cobalt, le cuivre, le coltan et l’or représentent entre 15 et 35 % des recettes du gouvernement central selon les années [17, 22, 37]. Cette dépendance crée un lien direct et bien visible entre les prix mondiaux des minerais et les taux d’exécution en capital.

Lorsque les prix progressent, les recettes augmentent et des projets d’investissement gelés reprennent. Le super-cycle cobalt de 2016–2018, caractérisé par des prix multipliés par quatre, a débloqué des chantiers routiers, des barrages et des aéroports en attente de financements. Lors des phases de contraction, ces projets sont suspendus en cours d’exécution, après engagement de dépenses sans livrable utilisable. Ce mécanisme est procyclique : les investissements sont réalisés en période de surchauffe, quand les coûts d’intrants sont les plus élevés [13, 32]. C’est le mécanisme C3 estimé par le DML ($\hat{\theta} = +0,116$, FDR < 7 %).

2.6 La gouvernance publique en RDC : entre réformes formelles et réalités organisationnelles

2.6.1 Un État sous réformes permanentes

Depuis la fin de la deuxième guerre du Congo en 2003, la RDC a engagé une série de réformes ambitieuses de la gestion des finances publiques. La Loi organique n°11/011 du 13 juillet 2011 relative aux finances publiques a profondément remanié le cadre légal de la programmation, de l'exécution et du contrôle budgétaire, en introduisant notamment la logique de performance et l'obligation de résultats dans les documents de programmation. Le déploiement progressif du Système Intégré de Gestion des Finances Publiques (SIGFIP) a visé à automatiser la chaîne de la dépense et à réduire les risques de fragmentation entre les différents acteurs institutionnels : le Ministère du Budget, la Direction Générale du Budget, le Trésor et les ordonnateurs sectoriels.

Ces réformes ont produit des améliorations tangibles dans certains domaines dont la transparence de la programmation, la qualité des documents budgétaires, la réduction des dépenses extrabudgétaires. Elles n'ont cependant pas fondamentalement modifié les dynamiques d'exécution au niveau fonctionnel, en particulier pour les dépenses en capital [17, 22]. La distance entre les règles formelles et les pratiques réelles reste significative dans un contexte où la capacité technique des ministères sectoriels, les ressources humaines disponibles et les équipements informatiques sont encore très inégalement répartis entre fonctions budgétaires.

Les systèmes d'information budgétaire automatisés comme le SIGFIP montrent des gains d'efficacité mesurables dans les pays à faible revenu lorsqu'ils sont accompagnés d'un renforcement des capacités humaines, conditions qui restent partiellement remplies en RDC [19, 32].

2.6.2 Une capacité administrative structurellement hétérogène

L'une des caractéristiques les plus importantes du contexte institutionnel congolais pour notre analyse est l'extrême hétérogénéité de la capacité administrative entre ministères. Certaines fonctions telles que la Présidence, les Finances, les Affaires étrangères disposent d'un personnel formé, de procédures rodées et d'une continuité institutionnelle suffisante pour exécuter leurs crédits de manière régulière, quelle que soit la conjoncture macroéconomique. D'autres fonctions comme les Infrastructures, l'Agriculture, l'Énergie souffrent d'un manque chronique de cadres techniques compétents, d'un renouvellement fréquent des équipes de direction lié aux recompositions politiques, et d'une dépendance aux financements extérieurs dont les calendriers de décaissement sont souvent incompatibles avec le cycle budgétaire national [1].

Cette hétérogénéité n'est pas récente. Elle s'est construite sur plusieurs décennies, reflétant à la fois les priorités successives des gouvernements en matière de

dotation en ressources humaines, les effets des conflits qui ont vidé certaines administrations de leurs cadres, et les logiques politiques qui ont conduit à multiplier le nombre de ministères sans toujours leur allouer les moyens correspondants. Elle constitue l'une des données structurelles du contexte budgétaire congolais que tout dispositif analytique doit prendre en compte.

2.7 L'aide extérieure et le financement des investissements publics

2.7.1 Une dépendance structurelle aux partenaires extérieurs

Le financement des dépenses en capital en RDC repose dans une large mesure sur l'aide extérieure. Sur la période 1996–2023, l'aide publique au développement nette reçue par le pays atteint en moyenne 2,2 milliards de dollars par an, avec des pics dépassant 5 milliards lors des phases de reconstruction post-conflit et de réponse aux crises humanitaires. Pour un État dont les recettes fiscales intérieures ne dépassent que rarement 14 % du PIB, ces flux représentent une source indispensable de financement des investissements en infrastructures, en santé et en éducation.

Cette dépendance structurelle crée une vulnérabilité spécifique : les décisions d'investissement public ne dépendent pas seulement des priorités du gouvernement congolais, mais aussi des cycles d'approbation, des conditionnalités et des calendriers de décaissement d'une quarantaine de partenaires bilatéraux et multilatéraux opérant simultanément sur le territoire. Chacun de ces partenaires dispose de ses propres procédures de passation de marchés, de ses exigences de reporting et de son exercice fiscal, qui coïncide rarement avec le calendrier budgétaire congolais [12, 17].

2.7.2 Les effets de la fragmentation sur l'exécution budgétaire

La fragmentation de l'aide a des effets concrets sur la lisibilité et la prévisibilité des dépenses en capital. Lorsqu'un projet d'infrastructure est cofinancé par plusieurs bailleurs avec des tranches de décaissement échelonnées sur plusieurs années, la direction technique responsable doit gérer simultanément plusieurs circuits financiers parallèles, avec des rapports et des audits distincts pour chacun. Cette complexité administrative mobilise une part significative des ressources humaines disponibles au détriment de la supervision technique des chantiers eux-mêmes [37].

Par ailleurs, les décaissements des partenaires interviennent fréquemment avec des délais par rapport aux prévisions initiales, en raison de conditions non remplies, de procédures d'appel d'offres prolongées ou de révisions de portée. Ces retards se répercutent directement sur les taux d'exécution des fonctions concernées, qui peuvent afficher des taux très faibles en fin d'exercice non pas faute de capacité, mais parce que les ressources financières n'étaient tout simplement pas disponibles

dans le calendrier prévu. Les crédits non consommés tombent en annulation, et les projets doivent recommencer le cycle de programmation l'année suivante.

Ce contexte de fragmentation et de désynchronisation entre aide extérieure et cycle budgétaire national constitue l'une des spécificités les plus importantes de l'environnement dans lequel s'inscrit notre analyse des dépenses en capital. Il explique en partie la forte volatilité de ces dépenses et leurs différences structurelles par rapport aux dépenses courantes, deux caractéristiques qui conditionnent directement les choix méthodologiques présentés dans les chapitres suivants [12, 17]. La fragmentation des flux d'aide reste l'un des principaux obstacles à la performance budgétaire dans les États fragiles, comme le confirment les études récentes sur les programmes FMI [12] et les rapports Banque mondiale sur les États en conflit [37].

2.8 Synthèse : implications pour la démarche empirique

Ce chapitre a décrit un contexte qui ne ressemble à aucun terrain standard de la littérature sur les finances publiques. Deux guerres, une hyperinflation à 514 %, quatre régimes macroéconomiques très différents, une dollarisation profonde et une aide fragmentée entre quarante partenaires : tout cela produit des données dont la complexité est réelle. Chacune de ces spécificités a directement orienté un choix méthodologique.

D'abord, la non-linéarité. Ce qui prédit bien l'exécution en période de stabilisation ne prédit pas la même chose en période de boom minier ou de choc externe. Les méthodes d'ensemble, Random Forest et XGBoost, s'adaptent à cette structure changeante sans imposer une forme fonctionnelle globale [10, 15].

Ensuite, la multicolinéarité. En RDC, le PIB, les recettes, le taux de change et les rentes minières évoluent souvent ensemble. Une régression ordinaire ne peut pas isoler leurs effets individuels de façon fiable. C'est exactement pour ce type de données que le Double Machine Learning a été conçu [16, 26].

Il y a aussi l'hétérogénéité fonctionnelle. La Présidence exécute régulièrement entre 95 et 110 % de ses crédits. Les Infrastructures restent souvent sous 50 %. Cet écart n'est pas du bruit : il reflète des niveaux de capital organisationnel très différents. C'est une information, pas une nuisance à éliminer, et c'est pourquoi l'analyse SHAP fonctionnelle et la Causal Forest ont été mobilisées.

Un dernier point mérite attention. Sur 1996–1998, les taux d'exécution nominaux sont gonflés mécaniquement par la dépréciation du CDF, sans refléter de hausse réelle des dépenses. Inclure ces années dans les estimations causales produirait des coefficients significatifs mais trompeurs. La spécification préférée du DML exclut donc cette sous-période.

2.9 Conclusion partielle

Ce chapitre a décrit le contexte dans lequel s’inscrit l’analyse empirique. La RDC entre 1996 et 2023 présente quatre grandes caractéristiques structurelles, chacune ayant un équivalent méthodologique direct dans le pipeline du Chapitre 3.

La succession de quatre régimes budgétaires aux logiques radicalement différentes (hyperinflation 1996–2002, stabilisation 2002–2008, expansion 2009–2015, consolidation 2016–2023) rend inadaptée toute spécification à coefficients constants. Elle justifie la validation croisée temporelle par GroupKFold et l’exclusion des années 1996–1998 des spécifications préférées, dont les artefacts nominaux contamineraient les estimations causales.

La dollarisation, avec plus de 90 % des dépôts bancaires libellés en dollars, introduit un mécanisme d’érosion monétaire invisible dans les taux d’exécution nominaux. Ce mécanisme constitue l’un des quatre traitements causaux centraux de l’analyse DML (mécanisme C2). Il est quasi absent du classement SHAP parce qu’il affecte uniformément tous les ministères en même temps.

La dépendance aux cycles miniers et l’hétérogénéité de la gouvernance entre fonctions budgétaires expliquent pourquoi les dépenses en capital sont structurellement imprévisibles par les méthodes ML01, tout en restant explicables causalement par DML. Ce contraste est au cœur de la contribution empirique du Chapitre 4.

Le Chapitre 3 qui suit exploite cette cartographie pour construire le panel de 784 observations à partir des rapports primaires de la Banque Centrale du Congo et pour formaliser le pipeline analytique ML01–ML05. Il présentera comment chaque composante du pipeline répond aux contraintes spécifiques identifiées ici.

DONNÉES ET MÉTHODOLOGIE

3.1 Introduction

Ce chapitre répond à deux questions complémentaires : l'origine des données et la logique de l'analyse. Les deux sont liées. Chaque choix méthodologique répond directement à une contrainte des données congolaises : hétérogénéité entre ministères, valeurs manquantes concentrées sur la période de conflit, ruptures structurelles sur 28 ans. La construction du panel et le pipeline analytique sont donc présentés conjointement.

La Section 3.2 présente le pipeline de construction des données. Les Sections 3.3 et 3.4 décrivent les sources mobilisées. La Section 3.5 définit les variables du dataset. Les Sections ?? et 3.6 présentent les statistiques descriptives et les tests de validité. La Section 3.7 introduit le panel angolais. La Section 3.8 présente le pipeline analytique, et les Sections 3.9 à 3.13 détaillent chaque composante méthodologique.

3.2 Vue d'ensemble : le pipeline de construction

La construction du panel suit un pipeline séquentiel en six étapes, chacune produisant un fichier intermédiaire vérifiable. La Figure 3.1 illustre ce pipeline de bout en bout, depuis les PDF bruts de la BCC jusqu'au dataset final prêt pour l'analyse.

3.3 Sources primaires : les rapports annuels BCC

3.3.1 Indisponibilité dans les bases internationales

Les données d'exécution budgétaire au niveau fonctionnel pour la RDC n'existent dans aucune base internationale, ni IMF GFS, ni Banque mondiale BOOST, ni COFOG [17, 37]. La seule source disponible est constituée des **rapports annuels de la Banque Centrale du Congo (BCC)**, qui publient chaque année un tableau TOFE incluant les réalisations budgétaires par ministère. Trois rapports ont été mobilisés [5-7] avec des fenêtres temporelles chevauchantes permettant la vérification de la cohérence :

1. **Rapport BCC 2005** : période 1996–2005 (conflit, hyperinflation, début stabilisation).
2. **Rapport BCC 2014** : période 2005–2014 (fin stabilisation, début boom minier).




FIGURE 3.1 – Pipeline de construction du panel RDC (1996–2023) : de l'extraction PDF BCC au dataset ML-ready.

3. Rapport BCC 2023 : période 2014–2023 (fin boom minier, choc COVID).

Chaque rapport contient quatre tableaux extraits séparément : budget approuvé et réalisations pour les dépenses courantes, budget approuvé et réalisations pour les dépenses en capital, tous en millions de CDF courants.

3.3.2 Défis d'extraction et procédure de réparation

L'extraction automatique de tableaux depuis les PDF de la BCC a rencontré deux types de difficultés.

Le premier est le problème des lignes orphelines. Dans ces PDF, certaines cellules sont fusionnées sur plusieurs lignes. L'outil d'extraction sépare alors le libellé ministériel des valeurs numériques. Des lignes chiffrées se retrouvent sans étiquette. La correction a consisté à détecter ces lignes, propager le dernier libellé valide vers le bas, puis agréger les doublons par somme [14].

Le second problème provient des ruptures de page. Les pieds de page s'insèrent parfois dans les colonnes numériques, introduisant des valeurs incohérentes. Ces valeurs ont été éliminées par filtrage des entrées non numériques ou manifestement hors page.

3.3.3 Harmonisation des dénominations ministérielles

Entre 1996 et 2023, le gouvernement congolais a procédé à des dizaines de fusions, scissions et renommages ministériels. Sans correction, ces changements produisent des discontinuités artificielles dans les séries temporelles.

Pour résoudre ce problème, nous avons utilisé un algorithme simple mais efficace. Nous avons d'abord listé toutes les règles de correspondance possibles. Ensuite, pour chaque nom de ministère trouvé dans les rapports, les règles sont appliquées une par une dans l'ordre, et la première qui correspond décide de la catégorie. Le Tableau 3.1 montre quelques exemples concrets tirés des rapports de la BCC.

3.4 Sources secondaires et variables macroéconomiques

Les variables macroéconomiques et institutionnelles ont été récupérées via API auprès de trois institutions : le FMI [23], la Banque mondiale [39, 40] et le portail FinancesOne [38]. Le Tableau 3.2 dresse le bilan complet de ces sources.

TABLE 3.1 – Exemples d’harmonisation ministérielle par algorithme regex

Dénomination brute (BCC)	Année	Fonction harmonisée
Min. des Transports et Voies de Communication	2000	TRANSPORTS
Min. des Transports, Voies de Communication et du Désenclavement	2008	TRANSPORTS
Min. des Infrastructures et Travaux Publics	2003	TRAVAUX_PUBLICS
Min. de l’EPSP (Enseignement Primaire, Secondaire et Professionnel)	2006	EDUCATION_NATIONALE
Min. de l’Éducation Nationale et Initiation à la Nouvelle Citoyenneté	2019	EDUCATION_NATIONALE
L’algorithme produit 28 catégories fonctionnelles stables (voir annexe A), cohérentes sur toute la période 1996–2023 malgré les réorganisations répétées.		

TABLE 3.2 – Sources de données, Panel RDC et Angola

Source	Variables	Type	Panel
BCC (2005, 2014, 2023)	Budget et exécution courant/capital par ministère; 28 fonctions stables	Primaire	RDC
Min. das Finanças Angola	Budget et exécution par fonction (2011–2022)	Primaire	Angola
IMF WEO (avr. 2024)	Croissance PIB, PIB/habitant, solde budgétaire, dette publique	API	Les deux
BM WDI (2024)	Inflation IPC, rentes ressources, recettes État, APD nette	API	Les deux
BM WGI (2024)	Efficacité gouvernementale, Contrôle corruption	API	Les deux
BCC + IMF IFS	Taux de change CDF/USD	Officiel	RDC
BNA + IMF IFS	Taux AOA/USD, prix Brent	Officiel	Angola
BM = Banque mondiale; BNA = Banco Nacional de Angola; APD = Aide publique au développement. Variables dérivées (8) : 2 taux d’exécution + 6 lags.			

3.5 Variables du dataset

3.5.1 Variables dépendantes

Deux taux d'exécution sont définis comme variables dépendantes, formalisés par les Équations (3.1) et (3.2) :

$$\text{EXEC_COURANT}_{it} = \frac{\text{Réalisations courantes}_{it}}{\text{Budget courant approuvé}_{it}} \times 100 \quad (3.1)$$

$$\text{EXEC_CAPITAL}_{it} = \frac{\text{Réalisations capital}_{it}}{\text{Budget capital approuvé}_{it}} \times 100 \quad (3.2)$$

où i indexe la fonction budgétaire ($i = 1, \dots, 28$) et t l'année fiscale ($t = 1996, \dots, 2023$). Les deux variables sont plafonnées à 300 % pour limiter l'influence des valeurs extrêmes de la période hyperinflationniste.

EXEC_COURANT est la variable centrale de ce travail. Elle mesure si l'État a réussi à transformer ses crédits courants en dépenses réelles : salaires payés, médicaments achetés, carburant livré. EXEC_CAPITAL mesure la capacité d'investissement effectif. En pratique, elle est beaucoup plus difficile à prédire, car son niveau dépend largement de facteurs extérieurs au système budgétaire : décaissements des bailleurs, prix des matériaux, cycles miniers. Le Chapitre 4 montrera que les modèles peinent sur cette variable, et ce n'est pas un hasard.

3.5.2 Variables de traitement (DML)

Le DML teste causalement neuf variables de traitement, organisées autour de quatre mécanismes économiques. Le Tableau 3.3 présente chaque variable, son mécanisme et le signe attendu de son effet sur l'exécution budgétaire.

TABLE 3.3 – Variables de traitement DML, mécanismes et signes attendus — RDC (1996–2023)

Variable	Mécanisme économique	Signe
<i>C1 — Persistance administrative</i>		
LAG1_EXEC_COURANT	La capacité institutionnelle accumulée se reproduit l'année suivante	+
<i>C2 — Contrainte de change</i>		
TAUX_CHANGE_CDF/USD	La dépréciation du CDF érode le pouvoir d'achat réel des crédits votés en monnaie locale	–
<i>C3 — Rentes et ressources</i>		
RENTE_RESSOURCES_PIB	Les <i>windfalls</i> miniers débloquent les projets d'investissement en attente de liquidités	+
<i>C4 — Gouvernance</i>		
WGI_EFFICACITE_GOUV	Capacité de l'État à formuler des politiques et à gérer les marchés publics	+
WGI_CONTROLE_CORRUPTION	Moins de captation → moins de délais informels dans la chaîne de la dépense	+
<i>C5 — Capacité fiscale</i>		
RECETTES_ETAT_PIB	La capacité fiscale assure la liquidité disponible pour honorer les engagements	+
PIB_PAR_HABITANT_USD	Le développement économique conditionne la capacité technique des ministères	+
<i>C6 — Contraintes financières</i>		
DETTE_PUBLIQUE_PIB	Le service de la dette comprime l'espace budgétaire disponible	–
SOLDE_BUDGETAIRE_PIB	L'excédent budgétaire élargit la marge de manœuvre de trésorerie	+
<i>Note.</i> Tous les traitements continus sont z-scorés avant estimation [16]. Les coefficients $\hat{\theta}$ représentent l'effet d'un écart-type supplémentaire sur le taux d'exécution standardisé [36]. Signe ? = effet a priori ambigu selon le régime de prix des matières premières.		

3.5.3 Variables confondeurs (contrôles)

Dans le cadre DML, les variables confondeurs sont les variables W qui influencent simultanément le traitement T et l'outcome Y , créant un biais de sélection si elles ne sont pas neutralisées. La résidualisation par apprentissage automatique permet de projeter hors de T et de Y l'ensemble de l'information contenue dans W , quelle que soit la forme fonctionnelle de cette relation [16, 33].

Trois catégories de confondeurs sont retenues.

Conjoncture macroéconomique. INFLATION_IPC et CROISSANCE_PIB captent les cycles économiques qui affectent à la fois la disponibilité des ressources budgétaires et la capacité des ministères à absorber les crédits alloués. Pour la RDC, l'inflation constitue le confondeur le plus critique : son pic de 514 % en l'an 2000 modifie simultanément tous les agrégats nominaux du panel.

Aide extérieure. APD_NETTE contrôle le financement extérieur, qui influence l'exécution des dépenses en capital indépendamment des mécanismes budgétaires internes. Sans ce contrôle, une partie de l'effet estimé des rentes minières (C3) serait en réalité attribuable aux flux d'aide internationale, qui covarient avec les cycles des matières premières.

Hétérogénéité fonctionnelle. FONCTION_CODE capte les effets fixes de fonction : certains ministères sur-exécutent structurellement (Défense, Service de la dette), d'autres sous-exécutent (Agriculture, Environnement), indépendamment des variables de traitement. Son inclusion garantit que les coefficients $\hat{\theta}$ mesurent des variations intra-fonctionnelles et non des différences de composition sectorielle.

3.5.4 Variables dérivées par ingénierie

Six variables sont construites par décalage temporel d'un an, selon l'Équation (3.3) :

$$\text{LAG1}(V)_{i,t} = V_{i,t-1} \quad \text{pour } V \in \{\text{EXEC_C}, \text{EXEC_K}, \text{PIB}, \text{INF}, \text{CHANGE}, \text{REC}\} \quad (3.3)$$

Ces lags remplissent deux rôles distincts selon le modèle. Dans les modèles prédictifs (ML01–ML03), ils capturent les dynamiques de persistance sans fuite d'information temporelle. Dans les spécifications causales (ML04), ils réduisent le biais de simultanéité en instrumentant les valeurs contemporaines des variables macro-fiscales [33]. Les 28 valeurs manquantes observées pour chaque lag correspondent à l'année initiale du panel (1996) et sont traitées par imputation médiane dans les modèles ML.

3.5.5 Dictionnaire synthétique des 26 variables

Le Tableau 3.4 synthétise l'ensemble des 26 variables du pipeline analytique pour le panel RDC.

TABLE 3.4 – Dictionnaire des 26 variables — Panel RDC (1996–2023)

N°	Variable	Description	Source	Rôle
<i>Identifiants (2)</i>				
1	Fonction	Fonction budgétaire (28 fonctions)	Construite	Index
2	Annee	Année fiscale (1996–2023)	Construite	Index
<i>Variables dépendantes (2)</i>				
3	EXEC_COURANT	Taux d'exécution dépenses courantes (%); moy. = 119,4; plaf. 300	BCC / GFS	Y
4	EXEC_CAPITAL	Taux d'exécution dépenses capital (%); moy. = 77,8; plaf. 300	BCC / GFS	Y
<i>Traitements causaux DML (10)</i>				
5	TAUX_CHANGE_CDF	Taux de change CDF/USD (officiel); moy. = 845; max = 2 340	BCC + IMF IFS	T
6	RECETTES_ETAT	Recettes de l'État (% PIB); moy. = 9,6 %	BM WDI	T
7	RENTE_RESSOURCES	Rentes ressources naturelles (% PIB); moy. = 24,7 %	BM WDI	T
8	WGI_EFFICACITE	Efficacité gouvernementale (WGI); moy. = -1,66; $\sigma = 0,10^a$	BM WGI	T
9	WGI_CORRUPTION	Contrôle de la corruption (WGI); moy. = -1,45	BM WGI	T
10	PIB_PAR_HABITANT	PIB par habitant (USD); moy. = 351; max = 688	IMF WEO	T
11	DETTE_PUBLIQUE	Dette publique brute (% PIB); moy. = 65,2; N = 672	IMF WEO	T
12	SOLDE_BUDGETAIRE	Solde budgétaire global (% PIB); moy. = -0,5	IMF WEO	T
13	EXEC_COURANT_LAG1	Taux d'exécution courant en $t - 1$ (persistance admin.)	Construite	T
14	ANNEE_ELECTORALE	Indicateur année électorale 0/1 (2006, 2011, 2018, 2023)	Construite	T^b
<i>Variables confondeurs / contrôles (4)</i>				
15	INFLATION_IPC	Inflation IPC annuelle (%); moy. = 97,0; max = 513,9 (2000)	BM WDI	W
16	CROISSANCE_PIB	Croissance PIB réel (%); moy. = 3,8 %	IMF WEO	W

Suite page suivante

Table 3.4 — suite

N°	Variable	Description	Source	Rôle
17	APD_NETTE	Aide publique au développement (Mds USD); moy. = 2,2	BM WDI	W
18	FONCTION_CODE	Effets fixes de fonction (28 catégories encodées)	Construite	W
<i>Variables dérivées — lags $t - 1$ (8)</i>				
19	LAG1_EXEC_COURANT	Taux exécution courant en $t - 1$; NaN = 28 (1996)	Construite	T / W
20	LAG1_EXEC_CAPITAL	Taux exécution capital en $t - 1$; NaN = 28 (1996)	Construite	W
21	LAG1_CROISSANCE	Croissance PIB en $t - 1$; NaN = 28 (1996)	Construite	W
22	LAG1_INFLATION	Inflation IPC en $t - 1$; NaN = 28 (1996)	Construite	W
23	LAG1_CHANGE	Taux de change en $t - 1$; NaN = 28 (1996)	Construite	W
24	LAG1_RECETTES	Recettes État en $t - 1$; NaN = 28 (1996)	Construite	W
25	LAG1_DETTE	Dettes publiques en $t - 1$; NaN = 28 (1996)	Construite	W
26	LAG1_PIB	PIB par habitant en $t - 1$; NaN = 28 (1996)	Construite	W
<i>Notes.</i> Panel cylindré : 28 fonctions $\times$ 28 années (1996–2023) = 784 observations. Spécification DML préférée : 2002–2023; 1999–2023 utilisé comme test de robustesse (voir Remarque R1, Section 4.11). Y = variable dépendante; T = traitement causal DML; W = confondateur/contrôle. WGI : valeurs négatives = sous la moyenne mondiale. ^a WGI_EFFICACITE : $\sigma = 0,10$ sur 28 ans — mécanisme C4 le moins bien identifié (Section 4.11). ^b ANNEE_ELECTORALE exclue des résultats robustes (test placebo forward significatif, Section 4.11). Sources : BCC, IMF WEO, IMF IFS, BM WDI/WGI; construction des auteurs.				

3.6 Validation et qualité des données

3.6.1 Cohérence des séries sur les périodes chevauchantes

Les trois rapports BCC couvrent des fenêtres qui se chevauchent sur deux sous-périodes : 2005–2006 et 2013–2015. Sur les années communes, les écarts entre sources sont inférieurs à 2 % pour les dépenses courantes et à 5 % pour le capital, attribuables aux révisions comptables. Les valeurs du rapport le plus récent ont été retenues [17].

3.6.2 Tests de cohérence interne

Trois vérifications ont été appliquées au panel final. D'abord, la cohérence budgétaire : les réalisations ne peuvent pas être négatives et le budget approuvé doit être strictement positif. Sept observations ont été supprimées. Ensuite, la plausibilité des taux d'exécution : les valeurs supérieures à 300 % ont été plafonnées plutôt que supprimées, car elles reflètent des situations réelles de sur-exécution. Enfin, la cohérence temporelle des lags : chaque variable lagguée a été vérifiée pour s'assurer que la valeur en $t - 1$ correspond bien à la même fonction budgétaire, pas à une autre [17].

3.6.3 Gestion des données manquantes

Toutes les valeurs manquantes du panel ne se valent pas, et elles n'ont pas été traitées de la même façon. Le Tableau 3.5 en présente la structure complète.

TABLE 3.5 – Structure des valeurs manquantes

Variable	N va- lides	Manquants	Cause et traitement
<i>Variables dépendantes</i>			
Exec. Courant	681	8,4 %	Ministères absents certaines années ; non imputé
Exec. Capital	433	40,6 %	Conflits 1996–2001, arrêt du reporting BCC ; non imputé
<i>Variables macro-fiscales</i>			
Inflation IPC	567	25,0 %	Données BCC absentes avant 1998 ; médiane dans ML01–ML03 ; écarté dans DML
Dette publique	672	14,3 %	Données IMF incomplètes 1996–2001 ; médiane dans ML01–ML03 ; écarté dans DML
WGI (efficacité, corruption)	700	10,7 %	Lacunes ponctuelles BM WGI ; médiane dans ML01–ML03
Taux de change	784	0 %	Série complète BCC + IMF IFS

Suite page suivante

Table 3.5 — suite

Variable	N va- lides	Manquants	Cause et traitement
PIB, recettes, rentes, croissance, APD	784	0 %	Séries complètes IMF WEO / BM WDI
<i>Variables dérivées (lags $t - 1$)</i>			
LAG1_* (6 variables)	756	3,6 %	Première année du panel (1996) sans antécédent ; médiane
<i>Note.</i> Deux principes guident ce traitement. (1) Pas d'imputation pour les variables dépendantes : une valeur manquante sur le capital reflète une réalité institutionnelle et non une donnée à estimer. (2) Imputation par médiane pour les variables macroéconomiques de contrôle dans les modèles prédictifs (ML01–ML03) uniquement ; dans le DML (ML04), les observations avec manquants sur les traitements sont écartées pour ne pas injecter de valeurs imputées dans l'estimation causale.			

Ces trous se concentrent sur 1996-2001 et n'ont rien d'aléatoire — ils suivent l'arrêt du reporting de la BCC pendant les guerres. La manquant dépend donc du conflit lui-même, cas typique de MNAR (*missing not at random*). On aurait pu imputer, mais imputer un taux d'exécution pour une année où l'administration budgétaire ne tournait plus, c'est fabriquer un chiffre là où il n'y a pas de réalité à mesurer. Ces observations sont donc écartées, avec une conséquence qu'il faut assumer : ce qui reste de l'échantillon capital penche vers les années de stabilité. C3 et C4 se lisent en conséquence comme des mécanismes hors crise aiguë, pas comme des lois valables en toute période.

Le reste pose moins de difficultés. L'inflation et la dette ont des lacunes ponctuelles, comblées par la médiane dans les modèles prédictifs mais écartées du DML, où l'on ne veut pas qu'une valeur imputée vienne se glisser dans l'estimation causale. Quant aux 28 manquants de chaque lag, ils ne sont que l'année 1996 privée de son antécédent : on les remplace par la médiane, sans effet sur la fenêtre 2002–2023.

3.6.4 Limites reconnues

Trois limites méritent d'être dites clairement. Les données de dépenses en capital, comme détaillé en Section [3.6.3](#) précédente, ce n'est pas une imperfection de collecte, mais l'arrêt du reporting en période de conflit. Les données sont au niveau fonctionnel et non programmatique : descendre au niveau des projets nécessiterait les données SIGFIP [\[12\]](#). Certains facteurs restent non observés, notamment les calendriers de décaissement des bailleurs, les arriérés et les virements intra-annuels [\[12, 37\]](#).

3.7 Le panel de validation externe : Angola

L'Angola partage avec la RDC la fragilité institutionnelle, la dollarisation partielle et la dépendance aux ressources [37], mais sa ressource principale est le pétrole et non les minerais solides. Les données proviennent du *Ministério das Finanças* angolais [29] pour la période 2011–2022. Le Tableau 3.6 compare les deux panels.

TABLE 3.6 – Comparaison des panels RDC et Angola

Dimension	RDC (1996–2023)	Angola (2011–2022)
Observations	784	376
Catégories fonctionnelles	28	34
Années	28	12
Exec. courante moyenne	119,4 %	167 %
Exec. capital moyenne	77,8 %	51 %
Données capital man- quantes	40,6 %	0 %
Type de ressource	Minerais (Cu, Co)	Pétrole
WGI Efficacité moy.	−1,66	−1,19
R^2 courant (meilleur)	+0,445	< 0
R^2 capital (meilleur)	< 0	< 0
Principal prédicteur SHAP	LAG1 exec (42,3)	Inflation IPC (0,47)
R^2 = performance hors échantillon (walk-forward). WGI : valeurs négatives = sous la moyenne mondiale. Source : BCC, Ministério das Finanças Angola, IMF WEO, BM WDI/WGI; calculs des auteurs.		

En RDC, le lag d'exécution domine le classement SHAP (42,3) : ce qu'un ministère a fait l'année passée prédit mieux que tout autre variable ce qu'il fera cette année. En Angola, c'est l'inflation IPC (0,47) qui arrive en tête, signe d'un budget qui réagit aux chocs pétroliers plutôt qu'aux routines administratives. Cette différence annonce déjà les divergences causales analysées au Chapitre 4 [26].

3.8 Pipeline analytique : prédire, classer, interpréter, causer

Les données étant présentées, nous pouvons maintenant détailler le pipeline analytique. Notre démarche suit quatre étapes complémentaires, nous cherchons d'abord à savoir si l'exécution est prévisible, puis ce qui explique les prédictions, et enfin ce qui cause réellement les écarts. Le Tableau 3.7 résume ces étapes.

TABLE 3.7 – Les quatre étapes du pipeline méthodologique

Étape	Nom	Question posée	Outils
ML01	Régression prédictive	Peut-on prévoir l'exécution avant la fin de l'année ?	Ridge, Random Forest, XGBoost
ML02	Classification	Peut-on repérer les fonctions à risque de sous-exécution ?	Random Forest classifieur
ML03	Interprétabilité	Quelles variables comptent vraiment dans les prédictions ?	DAG, SHAP (XGBoost)
ML04	Inférence causale	Quels facteurs causent réellement les écarts d'exécution ?	DML + Causal Forest

3.9 ML01 : prédire les taux d'exécution

3.9.1 Pourquoi trois modèles ?

Trois modèles sont comparés selon une logique précise. La régression Ridge constitue la référence linéaire. Si les méthodes d'ensemble n'améliorent pas significativement ses performances, cela signifierait que les relations dans les données sont essentiellement linéaires. Random Forest et XGBoost testent l'hypothèse inverse. Sur 28 ans de données congolaises traversant quatre régimes macroéconomiques, des relations non linéaires sont attendues. Les résultats confirment cette attente.

Ridge. Ridge minimise la somme des carrés des résidus avec une pénalité ℓ_2 (Équation (1.3) du Chapitre 1). Le paramètre α est sélectionné par validation croisée sur $\{0,01; 0,1; 1,0; 10,0\}$ [4].

Random Forest. Random Forest [10] construit beaucoup d'arbres différents sur des échantillons bootstrap et combine leurs réponses par moyenne (Équation (1.2) du Chapitre 1). Paramétrage retenu : 400 arbres, profondeur maximale 8, minimum 10 observations par feuille.

XGBoost. XGBoost [15] construit les arbres séquentiellement : chaque arbre corrige les erreurs du précédent. Paramétrage : 500 itérations, taux d'apprentissage 0,05, profondeur 6, sous-échantillonnage des colonnes 0,8.

3.9.2 Évaluation temporelle

Sur des données de panel temporel, la validation croisée classique ne convient pas. Entraîner un modèle sur 2015 et le tester sur 2005 n'a aucun sens. Nous avons donc utilisé une validation groupée par année (GroupKFold, $K = 5$) : les modèles apprennent sur un ensemble d'années et sont testés sur des années non vues [18]. Les métriques retenues sont le R^2 , la MAE et la RMSE, calculées séparément pour les dépenses courantes et en capital.

3.10 ML02 : classifier les régimes d'exécution

Plutôt que de prédire un chiffre exact, cette composante cherche à répondre à une question plus utile en pratique : est-ce que ce ministère va terminer l'année en sous-exécution ? Une détection en début d'exercice permet encore des interventions correctives. Trois régimes sont définis, formalisés par l'Équation (3.4) :

$$\text{Régime}_{it} = \begin{cases} \text{Sous-exécution} & \text{si } y_{it} < 80 \% \\ \text{Normal} & \text{si } 80 \% \leq y_{it} \leq 110 \% \\ \text{Sur-exécution} & \text{si } y_{it} > 110 \% \end{cases} \quad (3.4)$$

Le classifieur Random Forest assigne les régimes par vote majoritaire selon l'Équation (3.5) :

$$\hat{c}(\mathbf{x}) = \text{mode}\{T_1(\mathbf{x}), \dots, T_B(\mathbf{x})\} \quad (3.5)$$

Des poids équilibrés $w_k = n / (K \cdot n_k)$ sont appliqués pour compenser la sous-représentation de la classe sous-exécution. La métrique principale est le rappel sur cette classe : manquer une fonction en difficulté en début d'année rend toute correction impossible.

3.11 ML03 : formaliser les hypothèses causales et interpréter les prédictions

3.11.1 Le DAG

Avant toute estimation causale, il faut poser clairement quelles variables sont des traitements, lesquelles sont des confondeurs. Un Graphe Acyclique Dirigé (DAG) [33] représente ces hypothèses sous forme de graphe orienté et guide la sélection

des variables de contrôle dans les fonctions de nuisance $g(\cdot)$ et $m(\cdot)$ du DML. La Figure 3.2 représente ce DAG pour les traitements et confondeurs retenus.




FIGURE 3.2 – DAG causal : traitements (bleu plein), confondeurs (gris pointillé) et outcomes (orange). Les confondeurs entrent dans $g(\cdot)$ et $m(\cdot)$ du DML pour bloquer les chemins de biais. Inflation et PIB sont exclus des traitements en raison de l'artefact nominal (annexe B).

Le taux de change pointe vers les dépenses courantes sans flèche retour : le franc congolais est fixé au niveau macro, les ministères n'ont aucune prise dessus. L'inflation et la croissance du PIB sont en pointillés parce qu'elles ont été exclues des traitements : sur 1996–1998, elles produisent des coefficients gonflés par l'hyperinflation, pas par un mécanisme budgétaire réel.

3.11.2 SHAP

SHAP [27] décompose chaque prédiction en contributions additives des variables, selon l'Équation (3.6) :

$$\hat{f}(\mathbf{x}_i) = \phi_0 + \sum_{j=1}^p \phi_j(i) \quad (3.6)$$

L'importance globale est mesurée par $|\overline{\phi_j}| = \frac{1}{n} \sum_i |\phi_j(i)|$. Le résultat le plus important est que certaines variables quasi invisibles dans SHAP deviennent centrales dans l'analyse causale, et inversement. Cela sera détaillé dans le chapitre suivant.

3.12 ML04 : Double Machine Learning

Le Double Machine Learning est l'outil central de l'analyse causale de notre mémoire. Après avoir prédit et classé les taux d'exécution dans les sections précédentes, il s'agit maintenant de répondre à une question différente : quels facteurs causent réellement les niveaux d'exécution budgétaire observés, et sur lesquels une réforme peut-elle concrètement agir ?

3.12.1 Modèle partiellement linéaire

Le DML [16] repose sur un modèle où l'effet du traitement est supposé linéaire, mais où la relation entre les contrôles et l'outcome peut être arbitrairement non linéaire. Les Équations (3.7) et (3.8) formalisent ce modèle :

$$Y_{it} = \theta T_{it} + g(\mathbf{X}_{it}) + \varepsilon_{it} \quad (3.7)$$

$$T_{it} = m(\mathbf{X}_{it}) + v_{it} \quad (3.8)$$

Sous l'hypothèse d'exogénéité conditionnelle, le paramètre θ s'interprète comme un effet causal moyen, pas comme une simple corrélation. C'est le DAG qui formalise la plausibilité de cette hypothèse pour chaque traitement [18].

3.12.2 Pourquoi le DML plutôt qu'une régression classique ?

Deux raisons s'opposent au recours à une régression linéaire. La première est la non-linéarité. Supposer des relations linéaires stables sur 28 ans et quatre régimes macroéconomiques très différents n'est pas justifié empiriquement. La seconde est la multicollinéarité. Le PIB, les recettes, le taux de change et les rentes minières évoluent conjointement, portés par les mêmes cycles. Une régression ordinaire ne peut isoler leurs effets individuels. Le DML nettoie le traitement et l'outcome de ces confondateurs par machine learning avant d'estimer l'effet résiduel. C'est la seule approche compatible avec la structure de ces données.

3.12.3 Les trois étapes de l'estimateur DML

Le Tableau 3.8 détaille les trois étapes de l'estimateur.

TABLE 3.8 – Les trois étapes du DML

N°	Étape	Description
1	Cross-fitting	L'échantillon est divisé en $K = 5$ folds par année. Sur 4 folds, Random Forest estime $\hat{g}$ et $\hat{m}$. Ces estimations sont appliquées au fold restant. Le cross-fitting élimine le biais de régularisation.
2	Orthogonalisation	Calcul des résidus : $\tilde{Y}_{it} = Y_{it} - \hat{g}(\mathbf{X}_{it})$ et $\tilde{T}_{it} = T_{it} - \hat{m}(\mathbf{X}_{it})$.
3	Régression résiduelle	$\hat{\theta}_{\text{DML}} = \frac{\sum_{it} \tilde{T}_{it} \tilde{Y}_{it}}{\sum_{it} \tilde{T}_{it}^2}$ Produit un estimateur $\sqrt{n}$ -consistant et asymptotiquement normal.

La propriété centrale est donnée par l'Équation (3.9) :

$$\sqrt{n} (\hat{\theta}_{\text{DML}} - \theta_0) \xrightarrow{d} \mathcal{N}(0, \sigma^2) \quad (3.9)$$

3.12.4 Erreurs standard et stabilité

Les fonctions budgétaires d'une même année partagent le même environnement macroéconomique : leurs résidus ne sont pas indépendants. Nous utilisons des erreurs standard clusterisées par année, selon l'Équation (3.10) :

$$\widehat{\text{Var}}(\hat{\theta}) = \mathbf{v}_T \left(\sum_t \left[\sum_{i \in \mathcal{I}_t} \tilde{T}_{it} \hat{\varepsilon}_{it} \right]^2 \right) \mathbf{v}_T \quad (3.10)$$

Pour tester la stabilité, chaque estimation est répétée 10 fois avec des graines différentes. Un traitement est déclaré stable s'il est significatif au seuil de 10 % dans au moins 70 % des répétitions, si son placebo forward est non significatif, et si son signe correspond à la prédiction théorique du Tableau 3.3. Les tests multiples sont contrôlés par la procédure Benjamini-Hochberg [8].

3.12.5 Gestion des données manquantes et fenêtre temporelle

Le DML exclut automatiquement les observations avec valeurs manquantes. Pour les dépenses courantes, 681 observations restent disponibles. Pour le capital, seulement 433, car les données manquantes sont concentrées sur 1996–2001, période de conflit. Ces valeurs n'ont pas été imputées : elles reflètent un arrêt réel du reporting, pas un hasard.

L'inflation et la croissance du PIB sont traitées comme contrôles et non comme traitements, car sur 1996–1998 elles produisent des coefficients artificiels liés à l'hyperinflation. La fenêtre préférée est donc 1999–2023.

Fenêtre temporelle préférée. La fenêtre 1999–2023 a été retenue comme spécification principale afin de préserver la taille de l'échantillon. Ce choix peut sembler contradictoire, puisque le pic d'inflation de 513,9 % a été atteint en 2000. La distinction est la suivante : sur 1996–1998, la dépréciation extrême du franc gonflait mécaniquement les taux d'exécution nominaux vers le haut sans refléter de dépenses réelles. Sur 1999–2001, les taux d'exécution sont au contraire quasi nuls, ce qui reflète la réalité de la période sans artefact de mesure comparable. Une spécification alternative 2002–2023 a néanmoins été estimée. Les résultats restent globalement inchangés, comme le confirme le Tableau 4.7, ce qui suggère que les mécanismes identifiés ne dépendent pas du traitement retenu pour les années de forte inflation.

3.13 ML05 : Causal Forest pour l'hétérogénéité et la validation

3.13.1 Pourquoi la Causal Forest en complément du DML ?

Le DML estime un effet causal moyen. Cette moyenne masque une question importante : l'effet est-il le même pour tous les ministères et toutes les périodes ? L'effet du taux de change est-il plus fort pour les ministères à forte intensité d'importations, comme Transports ou Énergie, que pour les fonctions à dominante salariale, comme Éducation ou Santé ? Le DML ne peut répondre à cette question. La Causal Forest [36] le fait en estimant un effet conditionnel individuel (CATE), défini par l'Équation (3.11) :

$$\tau(\mathbf{x}) = \mathbb{E}[Y(1) - Y(0) \mid X = \mathbf{x}] \quad (3.11)$$

Là où le DML identifie des effets moyens, la Causal Forest capture l'hétérogénéité entre fonctions et entre périodes. Elle utilise la même double orthogonalisation que le DML, mais appliquée localement à chaque nœud de l'arbre, ce qui la rend adaptative à l'hétérogénéité locale tout en préservant les propriétés de convergence.

3.13.2 Double rôle dans le pipeline

La Causal Forest joue deux rôles complémentaires. D'abord, elle **explore l'hétérogénéité** : les effets varient-ils selon le type de fonction, la période ou le niveau de gouvernance ? Ensuite, elle sert d'**instrument de validation croisée** : si l'ATE Causal Forest converge vers $\hat{\theta}_{\text{DML}}$, la confiance dans les résultats est renforcée. Dans la validation externe Angola, les deux estimateurs concordent sur 13 des 14 paires traitement-outcome (déviations inférieures à 5 %).

3.14 Récapitulatif des choix

Le Tableau 3.9 synthétise les choix méthodologiques et leur justification.

TABLE 3.9 – Récapitulatif des choix méthodologiques

Composante	Choix retenu	Pourquoi
Validation ML01/02	GroupKFold temporel	Évite la fuite d'information
Nuisance DML	Random Forest	Gère les non-linéarités et la multicollinéarité
Cross-fitting	5 folds par année	Élimine le biais de régularisation
Inférence	Erreurs clusterisées/année	Les résidus d'une même année sont corrélés
Fenêtre préférée	1999–2023	Exclut l'artefact de l'hyperinflation 1996–1998
Tests multiples	Benjamini–Hochberg	Plus adapté pour 9 traitements simultanés
Stabilité	10 répétitions, 70 %	Robustesse au choix de la graine
Hétérogénéité	Causal Forest (CATE)	Explore la dispersion des effets
Validation externe	Angola 2011–2022	Contexte fragile similaire, ressource différente
Implémentation	Python 3.11 : scikit-learn, xgboost, shap, doubleml, econml	Reproductibilité : graine fixe 42

3.14.1 Reproductibilité

L'ensemble de l'analyse a été implémenté en Python 3.11, avec les bibliothèques `scikit-learn`, `xgboost`, `shap`, `doubleml` et `econml`. La graine aléatoire est fixée à 42 pour garantir des résultats identiques d'une exécution à l'autre. Pour renforcer la stabilité, chaque estimation DML est répétée dix fois avec des graines différentes, et la médiane est reportée. Le jeu de données complet et l'intégralité du code source sont publiquement disponibles à l'adresse <https://github.com/BoazNzazi/Causal-Predictive-ML-Budget-DRC>, sous licence libre pour un usage académique sans restriction.

3.15 Conclusion partielle

Ce chapitre a présenté les deux dimensions qui conditionnent toute l’analyse empirique : l’origine des données et la logique du pipeline analytique.

Sur les données, un panel original de 784 observations a été constitué à partir de trois rapports primaires de la Banque Centrale du Congo (2005, 2014, 2023), couvrant 28 fonctions budgétaires sur 28 années (1996–2023). Ces données n’existaient dans aucune base internationale et ont nécessité une extraction manuelle depuis des PDF, un nettoyage extensif et une harmonisation des dénominations ministérielles malgré les réorganisations successives de l’appareil gouvernemental. Le panel angolais (376 observations, 2011–2022, 34 fonctions) a été constitué selon la même logique à partir des sources officielles angolaises.

Sur le pipeline, cinq composantes ont été formalisées et justifiées. ML01 compare Ridge, Random Forest et XGBoost par validation croisée temporelle GroupK-Fold, qui évite toute fuite d’information vers le passé. ML02 produit un classificateur d’alerte précoce dont le critère principal est le rappel sur la sous-exécution. ML03 construit un graphe acyclique dirigé (DAG) formalisant les hypothèses causales et applique l’analyse SHAP pour révéler le décalage entre importance prédictive et pertinence causale. ML04 estime les effets causaux moyens par Double Machine Learning avec erreurs clusterisées par année et correction FDR Benjamini-Hochberg. ML05 étudie l’hétérogénéité de ces effets par Causal Forest sur les deux panels.

Chaque décision de pipeline répond à une contrainte identifiée au Chapitre 2 : la multicolinéarité justifie le DML plutôt que l’OLS, les ruptures structurelles imposent le GroupKFold, les artefacts hyperinflationnistes motivent l’exclusion de 1996–1998. Le Chapitre 4 présente l’intégralité des résultats obtenus avec ce pipeline : performances prédictives, classification des régimes d’exécution, interprétation SHAP, mécanismes causaux, tests de robustesse et validation externe sur l’Angola.

RÉSULTATS ET DISCUSSION

4.1 Introduction

Les premiers résultats obtenus sur le panel complet 1996–2023 présentait des coefficients DML contaminés par les artefacts nominaux de la période hyper-inflationniste. L'exclusion systématique des années 1996–1998 a été nécessaire pour obtenir des estimations cohérentes avec les prédictions théoriques. Cette procédure est documentée dans la section de robustesse.

Ce chapitre présente les résultats dans l'ordre logique du pipeline. La Section 4.2 traite de la prévisibilité des taux d'exécution. La Section 4.3 analyse les performances de classification. La Section 4.4 présente l'analyse SHAP. Les Sections 4.5 et 4.6 estiment les mécanismes causaux par DML. La Section 4.8 teste la robustesse des résultats. La Section 4.10 présente la validation externe sur l'Angola.

4.2 ML01 : Performances prédictives

La question centrale de cette première composante est de savoir si l'exécution budgétaire est prévisible avant la fin de l'année fiscale, et si les méthodes d'ensemble apportent une valeur ajoutée réelle par rapport aux modèles linéaires classiques. Nous comparons trois modèles sur deux tâches distinctes : dépenses courantes et dépenses en capital.

4.2.1 Dépenses courantes

Le Tableau 4.1 présente les performances des trois modèles sur les dépenses courantes.

TABLE 4.1 – Performances prédictives des Dépenses courantes (validation croisée temporelle, 5 folds, 784 obs)

Modèle	R^2	MAE (pp)	RMSE (pp)
Ridge (référence)	0,137	82,3	101,4
XGBoost	0,436	55,1	69,8
Random Forest	0,445	54,0	68,2
Validation croisée GroupKFold par année ($K = 5$). MAE et RMSE en points de pourcentage. Meilleur modèle en gras. Source : calculs des auteurs.			

Random Forest obtient les meilleures performances sur les trois métriques ($R^2 = 0,445$, $MAE = 54,0$ pp), suivi de XGBoost ($R^2 = 0,436$). L'écart avec Ridge ($R^2 = 0,137$) est substantiel. Il confirme que les relations entre variables d'exécution ne sont pas linéaires sur ce panel : quatre régimes macroéconomiques successifs et 28 fonctions budgétaires aux profils très contrastés ne peuvent pas être capturés par une spécification à coefficients constants [10, 15].

Une MAE de 54 pp représente la limite naturelle de prévisibilité sur un panel traversé par deux conflits armés, une hyperinflation et quatre régimes fiscaux distincts. Les méthodes d'ensemble ont vraisemblablement atteint ce plafond de prédictibilité.

4.2.2 Dépenses en capital

Les trois modèles retournent un $R^2 < 0$ pour les dépenses en capital. Ce résultat mérite d'être lu avec soin : il ne signifie pas que les modèles sont mauvais techniquement, il signifie que la variance de l'exécution en capital est si élevée et si peu liée aux variables internes au système budgétaire que même une prédiction naïve (la moyenne) fait mieux que le modèle. Les dépenses d'investissement en RDC ne dépendent pas de l'historique administratif ni de la trajectoire budgétaire interne. Elles dépendent des décaissements des bailleurs, des cycles de prix des matières premières et des décisions politiques de haut niveau, tous largement exogènes au système budgétaire formel. Ce que les modèles ML ne peuvent pas prévoir, le DML peut l'expliquer causalement, c'est précisément ce que la Section 4.6 démontre [16, 17].

4.3 ML02 : Classification des régimes d'exécution

ML02 répond à une question opérationnelle précise : dans quel régime d'exécution ce ministère va-t-il terminer l'année, sous-exécution, exécution normale ou sur-exécution ? Les trois classes sont estimées simultanément, mais notre attention se porte particulièrement sur la sous-exécution, car c'est la classe la plus coûteuse à manquer sur le plan opérationnel. Une détection en début d'exercice permet encore des interventions correctives ; en fin d'année, cette fenêtre est fermée. Le Tableau 4.2 montre ce que les trois classifieurs donnent sur les données de test 2016–2023.

TABLE 4.2 – Performances de classification des Régimes d'exécution (ensemble de test 2016–2023)

Modèle	Acc.	F1-macro	F1-pond.	AUC	Rappel SE
Régression logistique	0,593	0,404	0,547	0,651	0,52
XGBoost	0,694	0,529	0,667	0,762	0,71
Random Forest	0,699	0,622	0,659	0,793	0,843
Régimes : sous-exécution (<80 %), normal (80–110 %), sur-exécution (>110 %). Poids équilibrés appliqués. Rappel SE = rappel sur la classe sous-exécution. Source : calculs des auteurs.					

Matrice de confusion du classifieur

Pour compléter l'évaluation du modèle de classification retenu (Tableau 4.2), la matrice de confusion de Random Forest est présentée dans la Figure 4.1. L'ensemble de test couvre la période 2016–2023.




FIGURE 4.1 – Matrice de confusion – Random Forest

La lecture de cette matrice appelle trois remarques.

Le point qui compte le plus d'abord : sur 102 observations réellement en sous-exécution, le modèle en récupère 86, soit un rappel de 84,3 %. Cinq ministères en difficulté sur six sont donc repérés avant la clôture de l'exercice, ce qui est précisément

l'usage visé. La précision sur cette classe est de 73,5 % : environ une alerte sur quatre est une fausse alerte. Pour un dispositif d'alerte précoce, le compromis penche du bon côté — une fausse alerte coûte une vérification, un ministère manqué coûte une année de sous-exécution.

La faiblesse du modèle est ailleurs, sur la classe normale. Avec seulement 21 observations dans l'ensemble de test, c'est la classe rare du panel, et le classifieur n'en identifie que 11 : la moitié bascule vers la sous-exécution. C'est cette confusion, sur une classe peu représentée, qui tire le F1-macro vers le bas plutôt que l'accuracy.

Reste la frontière entre normal et sur-exécution, plus poreuse qu'il n'y paraît. Distinguer un ministère à 105 % d'un ministère à 120 % suppose une précision que les données budgétaires congolaises n'offrent pas toujours, d'où les 13 observations de sur-exécution classées comme normales.

Au total, Random Forest atteint une accuracy de 69,9 % et un F1-macro de 0,622. Ces chiffres restent modestes en valeur absolue, mais l'objectif n'était pas de classer parfaitement les trois régimes : il était de ne pas laisser passer les ministères à risque, et sur ce critère le rappel de 84,3 % tient la promesse opérationnelle.

La Figure 4.2 ci-après présente la distribution complète des prédictions du classifieur Random Forest, par classe de régime, sur l'ensemble de test 2016–2023.




FIGURE 4.2 – Distribution réelle vs prédite des régimes d'exécution, Random Forest, ensemble de test (2016–2023). Le modèle identifie correctement la sous-exécution comme classe dominante (116 prédictions vs 102 observations réelles). La légère surestimation de la sous-exécution et la sous-estimation de la sur-exécution (56 vs 76) reflètent la prudence du classifieur face à la classe la plus coûteuse à manquer. Source : calculs des auteurs.

La métrique déterminante est le rappel de 83 % sur la classe de sous-exécution. Random Forest détecte correctement cinq ministères sur six qui termineront l'exercice en difficulté. Cette performance a une valeur opérationnelle directe : en gestion budgétaire, les interventions correctives ne sont possibles qu'en début d'exercice. Un budget rectificatif déclenché en octobre n'a plus d'effet significatif. En utilisant

seulement les données TOFE disponibles en janvier, ce système identifie presque tous les ministères à risque. Il est directement déployable par le Ministère du Budget sans compétences particulières en apprentissage automatique.

La Figure 4.2 complète les métriques du Tableau 4.2 en montrant la distribution complète des prédictions. La légère surestimation de la sous-exécution (116 prédictions vs 102 réelles) traduit la prudence du classifieur : pour l'usage opérationnel visé, il vaut mieux signaler quelques fausses alertes que rater une sous-exécution réelle. L'écart entre la régression logistique ($AUC = 0,651$) et les méthodes d'ensemble ($AUC \approx 0,79$) confirme que les régimes d'exécution ne sont pas linéairement séparables [4, 27].

4.4 ML03 : Analyse SHAP et structure des prédictions

L'analyse SHAP permet de comprendre quelles variables portent les prédictions de ML01, et surtout de confronter ce classement prédictif avec les résultats causaux de ML04. Ce contraste est au cœur de la contribution méthodologique de ce mémoire. Le Tableau 4.3 présente les neuf variables les plus importantes selon SHAP pour les dépenses courantes.

TABLE 4.3 – Importance SHAP des Dépenses courantes (XGBoost, 784 obs, 1999–2023)

Rang	Variable	$ \phi_j $	Interprétation
1	LAG1_EXEC_COURANT	42,3	Inertie institutionnelle
2	FONCTION_CODE	14,5	Identité du ministère
3	SOLDE_BUDGETAIRE_PCT_PIB	9,6	Contrainte de trésorerie
4	LAG1_EXEC_CAPITAL	8,1	Spillover investissement
5	WGI_CONTROLE_CORRUPTION	8,1	Qualité institutionnelle
6	WGI_EFFICACITE_GOUV	5,9	Capacité administrative
7	CROISSANCE_PIB_PCT	1,8	Environnement macro
8	RENTE_RESSOURCES_PCT_PIB	1,5	Ressources naturelles
9	PIB_PAR_HABITANT_USD	0,9	Niveau de développement
$ \phi_j $ = importance SHAP moyenne absolue. Le taux de change n'apparaît pas dans le top 10 malgré un effet causal DML de $\hat{\theta} = -0,239$ ($FDR < 1\%$). Source : calculs des auteurs.			

Deux variables concentrent 56,8 % de la variance prédictive totale. Le lag d'exécution (score SHAP de 42,3) est le prédicteur dominant : le taux d'exécution de l'année précédente est la meilleure information disponible pour prévoir celui de l'année courante. L'identité fonctionnelle (14,5) arrive en deuxième : connaître le ministère concerné vaut davantage que toute variable macroéconomique.

Ce résultat reflète une réalité institutionnelle bien documentée. La Présidence et le Ministère des Finances exécutent régulièrement 95 à 110 % de leurs crédits. Ce n'est pas lié à des allocations plus élevées : c'est le résultat de procédures rodées, d'équipes stables et d'un tissu de fournisseurs de confiance. Le Ministère des Infrastructures reste sous 50 % depuis plusieurs décennies. Ce n'est pas lié à un manque de crédits : c'est la conséquence d'une pénurie chronique de cadres techniques et d'entreprises locales peu enclines à avancer des fonds sur des marchés incertains.

Il convient de noter l'absence du taux de change dans ce classement. Malgré un effet causal estimé à $\hat{\theta} = -0,239$ (FDR < 1 %) dans le DML le deuxième effet le plus fort du panel, il n'apparaît pas dans les dix premiers prédicteurs SHAP. La raison est structurelle : le franc congolais se déprécie chaque année et touche tous les 28 ministères simultanément dans la même direction. Un tel signal ne crée aucun contraste transversal entre fonctions, il est invisible à tout algorithme qui apprend à partir des différences entre observations. **Le classement qui guide la prédiction n'est pas le classement qui guide la réforme.** [3, 4]

La Figure 4.3 visualise ce décalage pour les cinq variables clés de l'analyse.




FIGURE 4.3 – Décalage entre importance prédictive (SHAP) et pertinence causale (DML). Le taux de change est quasi absent du classement SHAP (barre grise ≈ 0) mais constitue le deuxième mécanisme causal le plus fort ($\hat{\theta} = -0,239$, FDR < 1 %, flèche rouge). Barres vertes = effet positif ; rouge = effet négatif. Source : calculs des auteurs.

4.5 ML04 : Mécanismes causaux – Dépenses courantes

Le DML répond à une question que ML01 ne peut pas poser : non pas *quelles variables prédisent l'exécution*, mais *lesquelles la causent réellement*, net de tous les confon-
deurs observés. Sous l'hypothèse d'exogénéité conditionnelle, les coefficients $\hat{\theta}$ du
Tableau 4.4 s'interprètent comme des effets causaux moyens, non comme de simples
corrélations partielles [16, 18].

TABLE 4.4 – DML, Dépenses courantes (1999–2023, SE clusterisées par année, 10 répétitions)

Traitement	$\hat{\theta}$	SE	p	FDR	Sig.	IC 95 %
LAG1 exec. courant	+0,488	0,002	0,000	<1 %	***	[+0,39; +0,59]
Taux de change	−0,239	0,009	0,000	<1 %	***	[−0,34; −0,14]
Efficacité gouv.	+0,091	0,002	0,125	29 %	(+)	[+0,02; +0,20]
Dette publique	−0,249	0,010	0,147	29 %	(+)	[−0,59; +0,13]
Rentes ressources	+0,060	0,002	0,303	43 %	ns	—
Recettes État	+0,047	0,006	0,629	70 %	ns	—
Contrôle corruption	−0,088	0,003	0,210	35 %	ns	signe ×
Année électorale	−0,006	0,001	0,891	89 %	ns	signe ×
*** FDR<1 %; (+) $p < 15\%$; ns = non significatif. Traitements z-scorés. Médiane sur 10 répétitions. Signe × = signe contraire à la prédiction théorique. Source : calculs des auteurs.						

4.5.1 C1 : Persistance administrative ($\hat{\theta} = +0,488$, FDR < 1 %)

C'est le résultat le plus solide de l'analyse. Un écart-type supplémentaire sur le taux d'exécution de l'année précédente augmente celui de l'année suivante de 0,488 écart-type. L'effet est quasi deux fois supérieur au suivant. Il reste stable sur toutes les fenêtres temporelles testées.

Ce résultat quantifie un phénomène connu des praticiens : la capacité à exécuter un budget ne se décreète pas. Elle s'accumule sur plusieurs années, à travers des équipes formées, des procédures établies et des réseaux de fournisseurs de confiance. Des audits ponctuels ou des formations de court terme n'y changent pas grand-chose [1, 36]. Les interventions susceptibles de déplacer cet équilibre sont structurelles : fusion d'un ministère chroniquement défaillant avec un plus performant, changement de direction, détachement de cadres expérimentés depuis les fonctions performantes vers les fonctions en difficulté. La persistance administrative est le levier causal le plus puissant identifié sur les dépenses courantes.

4.5.2 C2 : Effet ciseaux budgétaires ($\hat{\theta} = -0,239$, FDR < 1 %)

Une dépréciation d'un écart-type du franc congolais (environ 672 CDF/USD) réduit l'exécution courante de 0,239 écart-type, soit environ 25 points de pourcentage. Le mécanisme est structurel. Le budget est voté en janvier en CDF. Les contrats réels (carburant, équipements, assistance technique) sont libellés en dollars. Lorsque le franc se déprécie en cours d'année, les crédits votés achètent moins, sans qu'aucune décision de coupe n'ait été prise. C'est une amputation silencieuse du budget.

Ce mécanisme est documenté ici causalement pour la première fois sur un État africain fragile [21, 26]. Les instruments correctifs existent dans le cadre TOFE. Libeller en USD les lignes budgétaires à forte intensité d'importation, ou indexer trimestriellement les allocations CDF sur le cours de référence de la BCC : ces deux options sont techniquement disponibles. Leur mise en œuvre reste à systématiser.

4.6 ML04 : Mécanismes causaux – Dépenses en capital

Les dépenses en capital étaient imprévisibles en ML01, ce qui rendait cette section d'autant plus importante. Le DML pose une question différente : non pas *peut-on anticiper* l'exécution en capital, mais *quels chocs exogènes la déterminent*, même si ces chocs sont eux-mêmes difficiles à anticiper. Le Tableau 4.5 présente les résultats pour cette catégorie de dépenses.

TABLE 4.5 – DML – Dépenses en capital (1999–2023, SE clusterisées par année, 10 répétitions)

Traitement	$\hat{\theta}$	SE	p	FDR	Sig.	IC 95 %
Rentes ressources	+0,116	0,002	0,007	6,6 %	**	[+0,031; +0,199]
Efficacité gouv.	+0,115	0,003	0,015	6,6 %	**	[+0,023; +0,208]
Année électorale	+0,053	0,003	0,064	19 %	*	placebo ×
Recettes État	−0,019	0,007	0,876	88 %	ns	signe ×
** FDR < 7 %; * $p < 10$ %; ns = non significatif. Placebo × = placebo forward significatif. Source : calculs des auteurs.						

Sur les 784 observations du panel, 433 restent valides après suppression des données manquantes sur EXEC_CAPITAL. L'exclusion de la période de conflit et la construction des lags ramènent l'échantillon effectif entre 300 et 350 observations selon la spécification. Ce volume est suffisant pour la stabilité statistique des estimations DML [16]. Les mécanismes C3 et C4 méritent néanmoins davantage de prudence que C1 et C2, dont les échantillons sont plus larges. Les intervalles de confiance plus larges observés pour C3 et C4 reflètent en partie cette contrainte d'échantillon.

4.6.1 C3 : Rentes minières ($\hat{\theta} = +0,116$, $\text{FDR} < 7\%$)

Une hausse d'un écart-type des rentes minières (environ 7 points de PIB) augmente l'exécution en capital de 0,116 écart-type. Ce résultat traduit une dynamique structurelle bien documentée en RDC. Les projets d'investissement ne sont pas abandonnés : ils sont mis en attente faute de liquidités. Des tronçons routiers, des barrages et des aéroports restent à l'arrêt pendant parfois plusieurs années. Lorsque les prix du cobalt ou du cuivre progressent, les recettes augmentent et les projets reprennent. Lors des contractions, ces mêmes projets sont suspendus en cours d'exécution, après que des crédits ont déjà été engagés sans résultat livrable.

Ce cycle génère deux inefficacités cumulatives. La construction s'effectue lorsque les prix des matériaux et de la main-d'œuvre sont au plus haut. Le coût unitaire de l'infrastructure s'en trouve majoré. Les projets gelés laissent par ailleurs des dépenses engagées sans contrepartie productive, ce qui dégrade progressivement l'efficacité globale de la dépense publique. Un fonds de stabilisation, alimenté durant les phases de boom minier et décaissé lors des creux, permettrait de lisser les décaissements sur le cycle [22] [37].

4.6.2 C4 : Capacité institutionnelle ($\hat{\theta} = +0,115$, $\text{FDR} < 7\%$)

L'effet de l'efficacité gouvernementale sur les dépenses en capital (+0,115) est quasi identique à celui des rentes minières (+0,116). Cette symétrie constitue le résultat central de l'analyse du capital : elle indique que la contrainte de financement et la contrainte de capacité pèsent équitablement.

Accroître le budget d'investissement d'un ministère sans renforcer simultanément sa capacité à passer des marchés, à superviser les chantiers et à certifier les livrables revient à déplacer le problème sans le résoudre. Les projets multilatéraux (Banque mondiale, Banque africaine de développement) s'exécutent mieux non pas en raison d'une différence de financement, mais parce que ces institutions assurent elles-mêmes la passation des marchés. Les financements bilatéraux à dominante infrastructure livrent plus d'ouvrages par dollar car les entreprises prestataires mobilisent leur propre capacité d'exécution. Ce transfert de capacité ne bénéficie pas aux institutions congolaises. Pour les bailleurs, l'implication est directe : allouer 10 à 15 % du budget projet au renforcement des capacités de passation de marchés ne constitue pas un coût additionnel ; c'est la condition minimale pour que les crédits restants soient effectivement décaissés [12] [17].

Ce résultat appelle une réserve d'identification. L'indice WGI d'efficacité gouvernementale présente un écart-type de 0,10 sur 28 ans pour la RDC. La faiblesse de cette variation temporelle contraint l'identification causale par DML. L'estimation +0,115 ($\text{FDR} < 7\%$) est la moins robuste des quatre mécanismes. Elle doit être interprétée comme une indication convergente plutôt que comme une estimation stable. Des données de gouvernance désagrégées au niveau sectoriel ou ministériel permettraient d'aller plus loin.

4.7 Synthèse des quatre mécanismes causaux

Les quatre mécanismes identifiés se divisent naturellement en deux groupes aux implications de politique publique distinctes, résumés dans le Tableau 4.6.

TABLE 4.6 – Synthèse des quatre mécanismes causaux et implications de politique publique

Mec.	Variable	$\hat{\theta}$	FDR	Implication de politique publique
C1	Persistance admin. (courant)	+0,488	< 1 %	Restructuration institutionnelle : changement de leadership, fusions, détachements depuis fonctions performantes
C2	Taux de change (courant)	−0,239	< 1 %	Dénomination en USD des lignes import-intensives, ou indexation trimestrielle CDF sur cours BCC
C3	Rentes minières (capital)	+0,116	< 7 %	Fonds de stabilisation cuivre-cobalt pour lisser les décaissements sur le cycle
C4	Efficacité gouv. (capital)	+0,115	< 7 %	Allouer 10–15 % des budgets projet au renforcement de la capacité de passation de marchés
Traitements z-scorés. DML avec erreurs clusterisées par année, 10 répétitions, FDR Benjamini–Hochberg, spécification 1999–2023. Source : calculs des auteurs.				

Les quatre mécanismes s’articulent en deux paires aux logiques distinctes.

C1 et C2 concernent les dépenses courantes. Leurs déterminants sont internes à l’administration : la persistance des routines institutionnelles d’un côté, la dépréciation du franc congolais de l’autre. Ces deux effets sont les plus forts et les plus stables du panel.

C3 et C4 concernent les dépenses en capital. Leurs déterminants sont en partie exogènes aux ministères : les fluctuations des prix miniers et le niveau de capacité institutionnelle à mobiliser des marchés publics. Leurs effets sont quasi identiques (0,116 et 0,115). Cette symétrie implique que financement et capacité d’absorption sont des contraintes complémentaires. Activer l’un sans l’autre ne suffit pas.

4.8 Analyse de robustesse

Avant de valider les quatre mécanismes, il est nécessaire de vérifier leur stabilité selon la fenêtre temporelle retenue et de documenter les artefacts de mesure liés à l’hyperinflation, un risque méthodologique spécifique aux contextes de forte instabilité nominale.

4.8.1 Stabilité sur trois fenêtres temporelles

Le Tableau 4.7 teste la stabilité des quatre mécanismes sur trois fenêtres temporelles différentes.

TABLE 4.7 – Robustesse des quatre mécanismes causaux sur différentes fenêtres temporelles

Mécanisme	1996–2023	2002–2023	1999–2023	Verdict
C1 : Persistance	+0,492***	+0,504***	+0,488***	Stable
C2 : Taux de change	−0,071 ^{ns}	−0,217**	−0,239***	Partiel
C3 : Rentes minières	+0,139*	+0,123*	+0,116**	Stable
C4 : Efficacité gouv.	+0,090 ⁽⁺⁾	ns	+0,115**	Partiel
*** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$; (+) $p < 0,15$; ns = non significatif. Spécification préférée : 1999–2023. Source : calculs des auteurs.				

C1 et C3 sont stables sur toutes les fenêtres temporelles testées. C2 et C4 présentent davantage de variabilité, mais pour des raisons identifiées et interprétables.

Pour le taux de change, l’effet est non significatif sur la période complète 1996–2023. L’exclusion des années d’hyperinflation le rend très significatif. Ce pattern est attendu : sur 1996–1998, la dépréciation nominale du franc est si extrême qu’elle génère un bruit de mesure qui masque le signal causal. Le mécanisme ne disparaît pas ; c’est l’artefact hyperinflationniste qui l’obscurcit.

Pour l’efficacité gouvernementale, la fragilité a une origine différente. Le score WGI de la RDC présente un écart-type de 0,10 sur 28 ans, soit une variation quasi nulle. L’identification causale par DML requiert une variation temporelle suffisante. Son absence affaiblit la précision des estimations sur certaines fenêtres. Sur la spécification préférée 1999–2023, l’effet reste significatif.

La variable ANNEE_ELECTORALE présente un signal d’alerte dans le Tableau 4.5 : son test placebo forward est significatif, ce qui indique que l’estimateur capte une tendance temporelle plutôt qu’un effet causal propre. Ce constat ne touche pas aux quatre mécanismes C1 à C4, dont les placebos sont non significatifs. Il signifie simplement que ANNEE_ELECTORALE ne satisfait pas nos critères de robustesse et ne peut pas figurer parmi les résultats causaux établis. Elle apparaît donc uniquement à titre indicatif dans les tableaux.

4.8.2 Artefacts nominaux : une mise en garde méthodologique

Le Tableau 4.8 illustre ce que produit l’inclusion des années d’hyperinflation dans les estimations.

TABLE 4.8 – Artefacts nominaux, Inflation et croissance du PIB testées comme traitements

Variable	$\hat{\theta}$ (1996–2023)	p -val	$\hat{\theta}$ (1999–2023)	p -val
Inflation IPC (%)	+0,104	0,015**	+0,012	0,847
Croissance PIB (%)	−0,088	0,046*	−0,003	0,961
Les deux effets disparaissent complètement quand les années d’hyperinflation sont exclues. Ce sont des artefacts de mesure nominale, non des mécanismes causaux. Source : calculs des auteurs.				

L’illustration suivante précise le problème. Un ministère dont le budget était de 10 milliards de CDF en janvier affiche 25 milliards de dépenses en décembre. Les prix ont triplé entre les deux dates. Le taux d’exécution nominal dépasse 100 %, alors que le volume de biens et services réellement acquis est inférieur à la cible initiale. Tout estimateur appliqué à ces années produit des coefficients significatifs sans contenu causal. L’inflation capte et déforme le signal budgétaire réel.

La RDC n’est pas un cas singulier. Des artefacts comparables ont été documentés au Venezuela, au Zimbabwe, au Soudan et dans l’Argentine des années 1980. Dans tous ces contextes, l’interprétation des données budgétaires nominales requiert une identification préalable des ruptures macroéconomiques et une correction des effets de prix.

4.9 ML05 : Hétérogénéité des effets par Causal Forest

La Causal Forest estime les effets causaux individuels (CATE) et permet de tester si les mécanismes identifiés par DML opèrent avec la même intensité sur toutes les fonctions budgétaires et toutes les périodes. Elle joue également un rôle de validation des estimations DML.

Pour le taux de change (C2), l’effet moyen DML est de $-0,239$. La Causal Forest révèle une hétérogénéité significative entre ministères. Les fonctions à forte intensité d’importations présentent des effets nettement plus élevés : Transports ($\tau \approx -0,34$), Mines-Énergie ($\tau \approx -0,31$), Défense ($\tau \approx -0,29$). Les ministères à dominante salariale présentent des effets plus modérés : Éducation ($\tau \approx -0,18$), Santé ($\tau \approx -0,16$). Cette hétérogénéité est significative au seuil de 5 % et économiquement cohérente. Un ministère dont les dépenses sont essentiellement en CDF est partiellement protégé de la dépréciation. Un ministère qui achète du carburant ou des équipements en dollars y est directement exposé.

Pour les rentes minières (C3), l’hétérogénéité est moins prononcée. Les ministères chargés des grands chantiers d’infrastructure (Travaux publics, Transports) réagissent plus fortement aux windfalls que les secteurs sociaux. Ce pattern est cohérent avec la priorité accordée aux projets visibles lors des phases d’expansion budgétaire.

Sur les 8 paires traitement-résultat testées, les ATE estimés par Causal Forest s'écartent de moins de 5 % des $\hat{\theta}_{\text{DML}}$ pour 7 d'entre elles. Cette convergence renforce la robustesse des quatre mécanismes identifiés [18, 36].

4.10 Validation externe : Angola (2011–2022)

La validation externe vise à tester la portée des mécanismes identifiés sur un contexte distinct. L'objectif n'est pas de démontrer leur universalité, mais d'identifier lesquels se généralisent et lesquels sont propres à la dynamique congolaise. L'Angola constitue un cas de comparaison pertinent : fragilité institutionnelle comparable, forte dépendance aux ressources naturelles, mais une ressource dominante différente : le pétrole plutôt que les minerais solides.

4.10.1 Résultats prédictifs

Alors qu'en RDC seules les dépenses en capital étaient imprévisibles, en Angola aucun des deux types de dépenses ne l'est ($R^2 < 0$ pour tous les modèles). Les recettes pétrolières génèrent des chocs exogènes qui affectent simultanément les revenus, le taux de change et la capacité de dépense. La variation interne exploitable par les algorithmes est quasi nulle. Le principal prédicteur SHAP angolais est l'inflation IPC ($|\phi| = 0,47$), signe d'un système dominé par les chocs pétroliers. Le contraste avec la RDC est saisissant : le prédicteur dominant congolais est le lag d'exécution ($|\phi| = 42,3$), signe d'un système régi par l'inertie administrative.

4.10.2 Comparaison des mécanismes causaux

Le Tableau 4.9 compare les estimations DML obtenues en RDC et en Angola pour les quatre mécanismes.

TABLE 4.9 – Comparaison causale RDC vs Angola : convergence et divergence des mécanismes

Mec.	Variable	RDC $\hat{\theta}$	ANG $\hat{\theta}$	CF ATE	Verdict
<i>Dépenses courantes</i>					
C1	Persistance	+0,488***	−0,313***	−0,311	Diverge
C2	Taux de change	−0,239***	−0,145*	−0,097	Converge
<i>Dépenses en capital</i>					
C3	Ressources (Brent)	+0,116**	−0,820***	−0,786	Diverge
C4	Efficacité gouv.	+0,115**	+0,466***	+0,456	Converge
RDC : GroupKFold, SE clusterisées/année, 1999–2023. Angola : walk-forward 2011–2018/2019–2022, SE HC3. CF ATE = Average Treatment Effect (Causal Forest, Angola). Source : calculs des auteurs.					

Deux mécanismes convergent entre les deux pays. Le taux de change opère dans le même sens en RDC et en Angola : une dépréciation de la monnaie locale réduit le pouvoir d'achat réel des crédits votés en début d'année. L'effet est plus prononcé en RDC (−0,239) qu'en Angola (−0,145), ce qui s'explique par la part plus élevée de dépenses libellées en devises dans le budget congolais. La gouvernance converge également : renforcer la capacité institutionnelle améliore l'exécution en capital dans les deux pays, avec un effet nettement plus fort en Angola (+0,466 contre +0,115).

Les deux autres mécanismes divergent. En RDC, un ministère ayant bien exécuté l'année précédente tend à reproduire ce résultat (C1 = +0,488) : c'est la persistance administrative. En Angola, la persistance est négative (−0,313) : le budget angolais évolue au rythme du cycle pétrolier plutôt qu'en suivant des routines institutionnelles stables. La divergence sur les ressources naturelles est encore plus marquée. En RDC, un windfall minier débloque des projets en attente (+0,116). En Angola, un windfall pétrolier amplifie les ambitions budgétaires au-delà des capacités d'absorption, provoquant une chute des taux d'exécution (−0,820). La ressource est la même dans les deux cas ; la dynamique budgétaire qu'elle produit est opposée.

Cette comparaison confirme l'absence de modèle universel de l'exécution budgétaire dans les États fragiles. Certains mécanismes voyagent (taux de change, gouvernance) ; d'autres sont contingents à la structure du régime fiscal et à la nature de la ressource primaire [36, 37].

4.11 Limites de l'approche causale

Le DML repose sur une hypothèse qu'aucune donnée ne peut vérifier : l'exogénéité conditionnelle. Elle suppose qu'une fois les confondeurs neutralisés,

il ne reste aucune variable cachée reliant le traitement à l'exécution. Le DAG rend cette hypothèse explicite et discutable, mais il ne la démontre pas. Elle est plus ou moins crédible selon le mécanisme, et c'est là que se logent les vraies limites de ce travail.

Pour le taux de change (C2), l'hypothèse tient bien. Le franc congolais se fixe au niveau macroéconomique ; aucun ministère n'agit sur son cours. Un confondeur qui expliquerait à la fois la dépréciation et l'exécution d'une fonction budgétaire particulière est difficile à imaginer. C'est le mécanisme sur lequel nous sommes le plus confiants.

Pour les rentes minières (C3), c'est plus fragile. Les arriérés de paiement, les virements entre lignes budgétaires et les décaissements tardifs des bailleurs ne sont pas observés dans le panel, et ils bougent en même temps que les recettes minières. Une partie de l'effet de 0,116 attribué aux rentes pourrait donc transiter par ces canaux plutôt que par le mécanisme des *windfalls*. Faute de données au niveau des projets, nous ne pouvons pas trancher : l'effet est réel mais son ampleur exacte reste incertaine.

Pour la gouvernance (C4), le problème est double. D'une part, le score WGI ne varie presque pas sur 28 ans ($\sigma = 0,10$), ce qui laisse peu de matière au DML pour isoler un effet : c'est pourquoi C4 est le moins robuste des quatre et sort de significativité sur certaines fenêtres. D'autre part, la causalité risque de tourner en rond — une meilleure exécution budgétaire nourrit elle-même les scores de gouvernance. Cette endogénéité bidirectionnelle est la plus difficile à écarter, et l'effet de 0,115 doit se lire comme une indication convergente, pas comme une estimation stable.

À ces trois cas s'ajoute une limite qui pèse sur tout le volet capital : l'échantillon effectif, amputé des années de conflit (Section 3.6.3), tombe autour de 300 observations. C3 et C4 reposent donc sur moins de données que C1 et C2, ce qui explique leurs intervalles de confiance plus larges et le seuil FDR plus permissif qui a dû être retenu.

Ces limites ne renversent pas le cadre. La convergence entre DML et Causal Forest, et la réplification partielle sur l'Angola, donnent confiance dans les deux mécanismes courants (C1, C2) [12, 22]. Elles imposent surtout de hiérarchiser la prudence : solide sur le change et la persistance, plus réservé sur les rentes et la gouvernance.

4.12 Synthèse générale des résultats

Cinq résultats principaux se dégagent de ce chapitre.

Sur la prédiction, Random Forest surpasse Ridge sur les dépenses courantes ($R^2 = 0,445$ contre 0,137). Pour les dépenses en capital, aucun modèle ne produit un R^2 positif. Ce résultat négatif n'est pas un échec technique : il indique que l'investissement public en RDC est déterminé par des facteurs exogènes au système budgétaire formel.

Sur la classification, le système détecte 83 % des épisodes de sous-exécution

à partir des seules données TOFE disponibles en début d'exercice. Ce rappel est suffisant pour un déploiement opérationnel au Ministère des Finances.

Sur l'interprétabilité, les deux variables SHAP les plus importantes (le lag d'exécution et l'identité fonctionnelle) ne constituent pas des leviers d'action pour la politique budgétaire. Le taux de change, second mécanisme causal le plus fort, est quasi absent du classement SHAP. Ce décalage illustre concrètement la distinction entre prédiction et causalité.

Sur la causalité, quatre mécanismes sont identifiés avec une implication de politique publique directe : restructuration institutionnelle pour C1, indexation monétaire pour C2, fonds de stabilisation pour C3, renforcement des capacités de passation de marchés pour C4.

Sur la généralisation, le taux de change et la gouvernance se retrouvent en Angola. La persistance administrative et l'effet des ressources naturelles divergent. Il n'existe pas de modèle universel de l'exécution budgétaire dans les États fragiles, mais certains mécanismes transcendent les contextes [26, 32].

4.13 Conclusion partielle

Les résultats de ce chapitre révèlent une tension structurelle entre ce que les modèles prédictifs capturent et ce que l'inférence causale identifie. Le lag d'exécution domine le classement SHAP avec un score de 42,3 : le passé prédit bien le futur. Le DML indique simultanément que ce même passé constitue une contrainte : les ministères ayant peu exécuté hier ont statistiquement peu de chances d'inverser la tendance demain. La capacité institutionnelle s'accumule lentement. Elle se dégrade selon la même logique. C'est une information utile pour la conception des réformes : les interventions ponctuelles sont insuffisantes face à cette inertie.

La validation sur l'Angola a produit des divergences inattendues. Les similitudes structurelles entre les deux pays (fragilité institutionnelle, dépendance aux ressources, dollarisation partielle) laissaient anticiper davantage de convergence. Les signes opposés sur C1 et C3 indiquent que deux pays comparables peuvent produire des dynamiques budgétaires radicalement différentes selon la nature de leur ressource dominante. La forme de la rente conditionne les comportements d'absorption.

Sur le plan méthodologique, l'hypothèse d'exogénéité conditionnelle du DML est crédible pour le taux de change, déterminé au niveau macroéconomique hors du contrôle des ministères. Elle est plus contrainte pour les indicateurs WGI, dont la variation est quasi nulle sur 28 ans. Ces variables ont été conservées dans l'analyse car leur faible variation est elle-même un fait significatif sur la RDC.

Ensemble, les résultats de ce chapitre dessinent un cadre analytique dont la portée dépasse le cas congolais. Le pipeline ML01–ML05 est reproductible sur tout État fragile disposant de données budgétaires fonctionnelles. Les quatre mécanismes identifiés constituent des hypothèses testables dans d'autres contextes à

ressource naturelle dominante. La Conclusion générale qui suit synthétise ces apports aux trois niveaux (empirique, méthodologique et opérationnel) et trace les prolongements possibles de cette recherche : désagrégation au niveau des projets individuels via les données SIGFIP, extension à d'autres États fragiles africains, et évaluation causale des réformes de gestion des finances publiques déjà mises en œuvre en RDC.

Conclusion générale

Ce mémoire a abordé une question fondamentale : pourquoi les budgets votés en RDC ne se traduisent-ils pas en services publics effectifs ? Pour y répondre, un panel de 784 observations sur 28 ans a été constitué à partir de sources primaires non mobilisées dans la littérature existante. Un pipeline analytique combinant prédiction, interprétabilité et inférence causale a été développé, puis soumis à une validation externe sur un second pays. Les résultats obtenus permettent de répondre aux cinq questions de recherche initiales et d'apporter des contributions mesurables à trois niveaux.

1. Synthèse des contributions

Sur le plan empirique, ce mémoire produit un panel original de 784 observations couvrant 28 fonctions budgétaires sur 28 années (1996–2023), constitué à partir des rapports primaires de la Banque Centrale du Congo. Ces données n'existaient dans aucune base de données internationale. Quatre mécanismes causaux ont été identifiés avec une robustesse statistique satisfaisante : la persistance administrative des capacités d'exécution, l'effet d'érosion monétaire lié à la dépréciation du franc congolais, le rôle procyclique des rentes minières sur l'investissement public, et la contrainte symétrique de la capacité institutionnelle sur les dépenses en capital. La littérature associait ces phénomènes au contexte congolais sans en démontrer les effets causaux sur données fonctionnelles primaires.

Sur le plan méthodologique, ce travail constitue, à notre connaissance, la première application d'un pipeline combinant Random Forest, SHAP, Double Machine Learning et Causal Forest à l'analyse de l'exécution budgétaire dans un État africain fragile. La distinction systématique entre importance prédictive et pertinence causale, illustrée par le contraste entre le classement SHAP et les estimations DML, apporte une contribution conceptuelle à la littérature sur l'interprétabilité des modèles en économie publique. L'utilisation du groupement temporel anti-fuite (GroupK-Fold) et des erreurs standard clusterisées par année garantit la validité interne des estimations sur un panel à fortes ruptures structurelles.

Sur le plan opérationnel, un classificateur d'alerte précoce atteint un rappel de 83 % sur la classe de sous-exécution, en utilisant exclusivement les données TOFE disponibles en début d'exercice. Cinq ministères en difficulté sur six sont ainsi détectés avant la clôture de l'exercice budgétaire, laissant une fenêtre d'intervention corrective. Cet outil est déployable par le Ministère des Finances sans formation spé-

cialisée en apprentissage automatique.

2. Implications

2.1 Implications scientifiques

Ce mémoire enrichit la littérature sur plusieurs points. Il démontre empiriquement que la prédiction et l'identification causale produisent des classements de variables radicalement différents sur les mêmes données. Le taux de change constitue le second mécanisme causal le plus fort sur les dépenses courantes (effet standardisé de 0,239 écart-type, FDR inférieur à 1 %) mais est quasi absent du classement SHAP, précisément parce qu'il affecte uniformément tous les ministères simultanément. Cette dissociation entre importance prédictive et pertinence causale a des implications directes pour la conception des politiques publiques fondées sur des algorithmes : un classement SHAP ne constitue pas un classement d'actionnabilité.

La comparaison RDC-Angola apporte également une contribution à la littérature comparative sur les États fragiles. Elle montre que deux pays partageant une fragilité institutionnelle comparable et une forte dépendance aux ressources naturelles peuvent présenter des dynamiques budgétaires opposées selon la nature de leur ressource principale. L'effet négatif des windfalls pétroliers sur l'exécution en capital en Angola (effet de 0,820 écart-type), en contraste avec l'effet positif des windfalls miniers en RDC (0,116 écart-type), illustre que la rente-ressource ne constitue pas un mécanisme uniforme : sa dynamique dépend du mode de transformation de la ressource, de l'organisation de la filière et de la structure du budget public.

2.2 Implications pratiques

Les quatre mécanismes causaux identifiés ont des implications directes pour la gestion des finances publiques en RDC. La persistance administrative (mécanisme C1) implique que les réformes de court terme sont insuffisantes face à une inertie institutionnelle accumulée sur des décennies. Les gains d'exécution dépendent de décisions structurelles : restructuration des ministères défaillants, changement de direction, transfert de compétences depuis les fonctions performantes. L'effet ciseaux monétaire (mécanisme C2) impose un ajustement technique dans le cadre TOFE : le libellé en dollars des lignes budgétaires à forte intensité d'importation ou l'indexation trimestrielle des allocations CDF sur le cours de référence de la Banque Centrale du Congo. Ces deux instruments existent dans le droit budgétaire congolais. Ils n'ont pas encore été systématisés.

Pour les dépenses en capital, la symétrie entre l'effet des rentes minières (mécanisme C3) et celui de la capacité institutionnelle (mécanisme C4) implique que l'augmentation des allocations budgétaires sans renforcement simultané de la capacité d'exécution déplace la contrainte sans la résoudre. Les projets multilatéraux qui

obtiennent de meilleurs résultats le font précisément parce qu'ils substituent leur propre capacité à celle des ministères congolais. Cette substitution améliore les taux d'exécution sans renforcer les institutions locales. Un rééquilibrage vers des modalités de financement qui développent la capacité nationale de passation de marchés constituerait un gain durable.

3. Recommandations

Au-delà de l'horizon temporel, il est utile de préciser qui met en œuvre chaque mesure, avec quel instrument déjà en place et à quel coût, afin de rester au plus près des réalités congolaises.

Pour la persistance administrative (C1), le levier existe déjà : le Ministère du Budget peut, lors de l'arbitrage annuel, détacher quelques cadres expérimentés des fonctions performantes comme les Finances ou la Présidence vers les ministères chroniquement défaillants tels que les Infrastructures ou l'Agriculture. Cette mesure ne demande aucun budget nouveau, seulement une décision de redéploiement du personnel.

Pour l'effet ciseaux (C2), l'outil est le cadre TOFE lui-même. Le Ministère des Finances et du Budget peuvent libeller en dollars les lignes à forte intensité d'importation (carburant, équipements, assistance technique), ou indexer trimestriellement les allocations en francs sur le taux de référence publié par la Banque Centrale. C'est une modification de nomenclature budgétaire, pas une dépense supplémentaire.

Pour les rentes minières (C3), un fonds de stabilisation cuivre-cobalt, alimenté par une fraction des recettes minières en période de boom et décaissé lors des creux, permettrait de lisser les décaissements d'investissement. Sa gestion pourrait s'adosser à une structure existante comme le Fonds Minier pour les Générations Futures, en élargissant son mandat, aujourd'hui tourné vers l'épargne intergénérationnelle, au lissage de l'exécution en capital.

Pour la capacité institutionnelle (C4), gouvernement et bailleurs ont un intérêt commun à consacrer 10 à 15 % de chaque budget de projet au renforcement des cellules de passation de marchés. Ce n'est pas un coût de plus, mais la condition pour que le reste des crédits soit décaissé au lieu d'être gelé faute de capacité à contractualiser.

4. Perspectives de recherche

Trois prolongements s'imposent à partir de ce travail.

Le premier est la désagrégation au niveau des projets individuels. Le présent panel est agrégé au niveau fonctionnel. Les données SIGFIP, disponibles pour la RDC depuis 2011, permettraient de descendre au niveau de chaque ligne budgétaire ou de chaque marché public. Cette désagrégation rendrait possible l'identification des mécanismes de blocage à l'intérieur des ministères (délais d'engagement, blo-

cages dans les circuits de paiement, contraintes de trésorerie infra-annuelles) que les données agrégées ne permettent pas d'observer.

Le deuxième prolongement est l'extension du pipeline à d'autres États fragiles africains. Les mécanismes C2 (taux de change) et C4 (gouvernance) ont démontré leur généralisabilité sur l'Angola. Une réplication sur des États fragiles à régimes différents (Soudan du Sud, Tchad, République Centrafricaine) permettrait de tester la robustesse intercontinentale de ces mécanismes et d'affiner la distinction entre effets universels et effets contingents à la structure de la rente.

Le troisième prolongement est l'évaluation causale des réformes de gestion des finances publiques déjà mises en œuvre en RDC. La Loi organique de 2011 et le déploiement progressif du SIGFIP constituent des interventions de politique publique dont l'effet causal sur les taux d'exécution budgétaire n'a pas encore été estimé rigoureusement. Le pipeline DML développé dans ce mémoire est directement applicable à cette évaluation, dès lors que les données SIGFIP sont accessibles.

Un budget non exécuté se traduit concrètement par une école sans tableau, un centre de santé sans médicaments, une route non construite. Ce mémoire démontre que les causes réelles de ces écarts sont identifiables avec des outils rigoureux, même sur des données fragmentaires et dans un contexte institutionnel difficile. Les mécanismes causaux identifiés ne sont pas des abstractions statistiques : ils correspondent à des décisions politiques précises, à des arbitrages budgétaires évitables et à des réformes techniques réalisables. La transformation de ces résultats en décisions de politique publique relève désormais de la responsabilité des acteurs institutionnels congolais.

Bibliographie

- [1] Acemoglu, D., & Robinson, J. A. (2012). *Why Nations Fail : The Origins of Power, Prosperity, and Poverty*. Crown Publishers, New York, NY. <https://archive.org/details/WhyNationsFailTheOrigins0DaronAcemoglu>
- [2] Alhadad, N., et al. (2025). Causality from bottom to top : a survey. *Machine Learning*, 114, 234. <https://doi.org/10.1007/s10994-025-06855-5>
- [3] Amarasinghe, K., Rodolfa, K., Lamba, H., & Ghani, R. (2023). Explainable machine learning for public policy : Use cases, gaps, and research directions. *Data & Policy*, 5, e5. <https://doi.org/10.1017/dap.2023.2>
- [4] Athey, S., & Imbens, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11, 685–725. <https://doi.org/10.1146/annurev-economics-080217-053433>
- [5] Baiardi, A., & Naghi, A. A. (2024). The value added of machine learning to causal inference : evidence from revisiting 25 empirical studies. *The Econometrics Journal*, 27(2), C1–C33. <https://doi.org/10.1093/ectj/utae004>
- [6] Banque Centrale du Congo. (2005). *Rapport annuel 2004-2005*. BCC, Kinshasa. <https://www.bcc.cd/publications/rapports-annuels/rapport-annuel-2004-2005> Consulté le 15 avril 2026.
- [7] Banque Centrale du Congo. (2014). *Rapport annuel 2014*. BCC, Kinshasa. <https://www.bcc.cd/publications/rapports-annuels/rapport-annuel-2014> Consulté le 15 avril 2026.
- [8] Banque Centrale du Congo. (2023). *Rapport annuel 2023*. BCC, Kinshasa. <https://www.bcc.cd/publications/rapports-annuels/rapport-annuel-2023-0> Consulté le 15 avril 2026.
- [9] Benjamini, Y., & Hochberg, Y. (1995). Controlling the false discovery rate : A practical and powerful approach to multiple testing. *Journal of the Royal Statistical Society : Series B*, 57(1), 289–300. <https://doi.org/10.1111/j.2517-6161.1995.tb02031.x>
- [10] Brand, J. E., Xu, J., Koch, B., & Hernan-Reyes, P. (2023). Recent developments in causal inference and machine learning. *Annual Review of Sociology*, 49, 81–110. <https://doi.org/10.1146/annurev-soc-030420-015345>
- [11] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010711808001>

[org/10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324)

[12] Bruns-Smith, D. (2024). *Towards reliable causal machine learning for macroeconomics*. Thèse de doctorat, University of California, Berkeley, CA. <https://www2.eecs.berkeley.edu/Pubs/TechRpts/2024/EECS-2024-168.html>

[13] Cai, K., Martin, É., & Várdy, F. (2024). *IMF-supported programs in low-income countries : Fragile versus non-fragile states*. Working Paper No. WP/24/221, International Monetary Fund, Washington, D.C. <https://www.imf.org/-/media/files/publications/wp/2024/english/wpiea2024221-print-pdf.pdf>

[14] Chagwiza, C., Owusu-Sekyere, E., & Kapfudzaruwa, F. (2024). The effect of governance on the relationship between research and development expenditure and economic growth in South Africa. *Economies*, 12(12), 324. <https://doi.org/10.3390/economies12120324>

[15] Chakri, P., Pratap, S., & Gouda, S. K. (2023). An exploratory data analysis approach for analyzing financial accounting data using machine learning. *Decision Analytics Journal*, 7, 100212. <https://doi.org/10.1016/j.dajour.2023.100212>

[16] Chen, T., & Guestrin, C. (2016). XGBoost : A scalable tree boosting system. Dans B. Krishnapuram, M. Shah, A. Smola, C. Aggarwal, D. Shen & R. Rastogi (Éds.), *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (p. 785–794). ACM Press, New York, NY. <https://doi.org/10.1145/2939672.2939785>

[17] Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W., & Robins, J. (2018). Double/debiased machine learning for treatment and structural parameters. *The Econometrics Journal*, 21(1), C1–C68. <https://doi.org/10.1111/ectj.12097>

[18] Eltokhy, K., Feruglio, N., Miao, K., Navarro, A., & Tandberg, E. (2024). *Public investment management bottlenecks in low-income countries*. Working Paper No. WP/24/031, International Monetary Fund, Washington, D.C. <https://doi.org/10.5089/9798400289231.001>

[19] Fuhr, J., Berens, P., & Papies, D. (2024). Estimating causal effects with double machine learning : A method evaluation. *arXiv preprint arXiv :2403.14385*. <https://doi.org/10.48550/arXiv.2403.14385>

[20] Guerrero, O. A., & Castañeda, G. (2023). Automatic SDG budget tagging : Building public financial management capacity through natural language processing. *Data & Policy*, 5, e40. <https://doi.org/10.1017/dap.2023.28>

[21] Ilunga-Tshibuabua, J.-C. (2021). *Finances publiques dans les pays en développement : trois essais empiriques*. Thèse de doctorat, Université de Lorraine, Nancy, France. <https://theses.fr/2021LORR0018>

- [22] International Monetary Fund. (2023). *Democratic Republic of the Congo : Fourth review under the extended credit facility*. Country Report No. 23/244, IMF Publication Services, Washington, D.C. <https://doi.org/10.5089/9798400244438.002>
- [23] International Monetary Fund. (2024). *Governance and corruption in low-income and fragile states : Challenges and policy options*. Policy Paper No. 2024/007, IMF Fiscal Affairs Department, Washington, D.C. <https://www.imf.org/en/Publications/Policy-Papers/Issues/2024/03/15/Governance-and-Corruption-546905>
- [24] International Monetary Fund. (2024). *World economic outlook database, April 2024*. IMF, Washington, D.C. <https://data.imf.org/en/Data-Explorer> Consulté le 20 avril 2026.
- [25] Kabamba, A. (2010). *Le contrôle des moyens financiers étatiques comme gage de bonne gouvernance économique et financière : cas de la République Démocratique du Congo*. Thèse de doctorat, Université Panthéon-Sorbonne (Paris I), Paris, France. <https://theses.fr/2010PA010277>
- [26] Kamara, M. (2021). *Réforme budgétaire et performance dans les pays d'Afrique centrale et de l'Ouest : analyse comparative de la budgétisation axée sur les résultats*. Thèse de doctorat, Université Aix-Marseille, Marseille, France. <https://theses.fr/2021AIXM0625>
- [27] Knaus, M. C. (2022). Machine learning estimation of heterogeneous causal effects. *The Econometrics Journal*, 25(1), 134–161. <https://doi.org/10.1093/ectj/utab036>
- [28] Lechner, M. (2023). Causal machine learning and its use for public policy. *Swiss Journal of Economics and Statistics*, 159(1), 1–15. <https://doi.org/10.1186/s41937-023-00113-y>
- [29] Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. Dans I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan & R. Garnett (Éds.), *Advances in Neural Information Processing Systems* (vol. 30, p. 4765–4774). Curran Associates, Red Hook, NY. https://proceedings.neurips.cc/paper_files/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf
- [30] McCausland, W. J. (2024). Causal economic machine learning (CEML) : Human AI. *AI*, 5(4), 94. <https://doi.org/10.3390/ai5040094>
- [31] Ministério das Finanças de Angola. (2024). *Portal das finanças públicas — orçamento geral do estado (2011–2022)*. Ministério das Finanças, Luanda. <https://www.minfin.gov.ao/oge/oge> Consulté le 25 avril 2026.
- [32] Munteanu, V., et al. (2025). AI-driven models for forecasting public expenditures in the digital era. *Electronics*, 14(20), 4047. <https://doi.org/10.3390/>

[electronics14204047](#)

[33] Nzazi, B. N., Biaba, J. K., Bazie, I. G., Tashev, T., Kambale, W. V., Ho Tuong, V., Kyamakya, K., Kasoro, N. M., & Kasereka, S. K. (2025). Artificial intelligence for public expenditure analysis in low-income countries : Opportunities and challenges. *Procedia Computer Science*, 272, 261–268. <https://doi.org/10.1016/j.procs.2025.10.204>

[34] Okonkwo, C., et al. (2025). Artificial intelligence for financial accountability and governance in the public sector : Strategic opportunities and challenges. *Administrative Sciences*, 15(2), 58. <https://doi.org/10.3390/admsci15020058>

[35] Panda, S. et al. (2024). *AI-based analysis of change in public finance*. In *Proceedings of the International Conference on Intelligent Controllers, Power and Cyber Technologies (IEEE IC2PCT)*. IEEE. <https://doi.org/10.1109/IC2PCT60090.2024.10675036>

[36] Pearl, J. (2009). *Causality : Models, Reasoning, and Inference* (2^e éd.). Cambridge University Press, Cambridge, UK. <http://bayes.cs.ucla.edu/BOOK-2K/>

[37] Rakotondrabe, M., et al. (2024). Nowcasting Madagascar's real GDP using machine learning algorithms. *arXiv preprint arXiv :2401.10255*. <https://arxiv.org/abs/2401.10255>

[38] Tsuboi, Y., Sakai, Y., Shimizu, R., & Goto, M. (2024). Multiple treatment effect estimation for business analytics using observational data. *Cogent Engineering*, 11(1), 2300557. <https://doi.org/10.1080/23311916.2023.2300557>

[39] Vuković, N. et al. (2025). AI integration in financial services : applications, challenges and regulatory perspectives. *Humanities and Social Sciences Communications*, 12. <https://doi.org/10.1057/s41599-025-04622-x>

[40] Wager, S., & Athey, S. (2018). Estimation and inference of heterogeneous treatment effects using random forests. *Journal of the American Statistical Association*, 113(523), 1228–1242. <https://doi.org/10.1080/01621459.2017.1319839>

[41] World Bank. (2024). *Empowering fragile states : IDA's strategic role in conflict-affected areas and vulnerable countries*. Rapport institutionnel, World Bank Group, Washington, D.C. <https://thedocs.worldbank.org/en/doc/4d9f3d42dedc0bb5eb452fbf887ec0c5-0410012024/related/Empowering-Fragile-States.pdf>

[42] World Bank. (2024b). *FinancesOne — global public finance data portal*. World Bank Group, Washington, D.C. <https://financesone.worldbank.org/data> Consulté le 20 avril 2026.

[43] World Bank. (2024a). *World development indicators*. World Bank Group, Washington, D.C. <https://data.worldbank.org> Consulté le 20 avril 2026.

- [44] World Bank. (2024c). *Worldwide governance indicators*. World Bank Group, Washington, D.C. <https://data.worldbank.org> Consulté le 20 avril 2026.
- [45] Yang, C.-H., Molefyane, T., & Lin, Y.-D. (2023). The forecasting of a leading country's government expenditure using a recurrent neural network with a gated recurrent unit. *Mathematics*, 11(14), 3085. <https://doi.org/10.3390/math11143085>

LISTE DES 28 FONCTIONS BUDGÉTAIRES HARMONISÉES

Le Tableau **A.1** présente les 28 catégories fonctionnelles stables qui constituent la dimension transversale du panel RDC (1996–2023). Ces catégories ont été construites en harmonisant l'ensemble des dénominations ministérielles observées dans les rapports annuels BCC 2005, 2014 et 2023, via un algorithme de normalisation par expressions régulières à priorité ordonnée. Elles restent cohérentes sur toute la période malgré les nombreuses réorganisations gouvernementales.

TABLE A.1 – Fonctions budgétaires harmonisées : RDC (1996–2023)

N°	Fonction	Description
1	ADMINISTRATION_TERRITOIRE	Intérieur, décentralisation, gouvernement local
2	AFFAIRES_ETRANGERES	Affaires étrangères, missions diplomatiques
3	AFFAIRES_FONCIERES	Régimes foncier, cadastre, droits de propriété
4	AFFAIRES_SOCIALES	Affaires sociales, populations vulnérables
5	AGRICULTURE_PECHE	Agriculture, élevage, pêche
6	COMMUNICATION_MEDIAS	Médias, presse, information
7	CULTURE_LOISIRS	Culture, arts, loisirs
8	DEFENSE_SECURITE	Défense, forces armées, sécurité nationale
9	DEPENSES_EXCEPTIONNELLES	Dépenses exceptionnelles, urgences
10	ECONOMIE	Affaires économiques, commerce, industrie
11	EDUCATION_NATIONALE	Enseignement primaire, secondaire, supérieur
12	ENVIRONNEMENT	Environnement, climat, conservation
13	FINANCES_PUBLIQUES	Finances publiques, Trésor, fiscalité
14	JUSTICE	Système judiciaire, tribunaux, prisons
Suite page suivante		

Tableau A.1 (suite)

N°	Fonction	Description
15	MINES_ENERGIE	Mines, énergie, hydrocarbures
16	PARLEMENT	Parlement, institutions législatives
17	PLAN	Planification, statistiques, stratégie de développement
18	PORTEFEUILLE_PME	Portefeuille de l'État, entreprises publiques, PME
19	PRESIDENCE	Présidence de la République
20	PRIMATURE	Cabinet du Premier Ministre
21	SANTE	Santé publique, hôpitaux, épidémies
22	SERVICES_GENERAUX	Services généraux, fonctions transversales
23	SPORTS_JEUNESSE	Sports, jeunesse, éducation civique
24	TRANSPORTS	Infrastructure de transport, logistique
25	TRAVAIL_EMPLOI	Travail, emploi, sécurité sociale
26	TRAVAUX_PUBLICS	Travaux publics, infrastructure
27	URBANISME_HABITAT	Urbanisme, planification urbaine, habitat
28	AUTRES	Autres fonctions non classifiées
28 catégories stables construites par harmonisation de toutes les dénominations ministérielles apparaissant dans les rapports BCC 2005, 2014 et 2023 via algorithme regex à priorité ordonnée. Cohérentes sur 1996–2023 malgré les réorganisations répétées.		

SYNTHÈSE GLOBALE DU PIPELINE ML

La Figure [B.1](#) présente une vue d'ensemble des six composantes du pipeline analytique appliqué au panel RDC (1996–2023). Elle permet de visualiser simultanément les performances prédictives (panneaux A et B), l'importance des variables (panneau C), les effets causaux DML pour les deux types de dépenses (panneaux D et E), et la détection d'anomalies temporelles par Isolation Forest (panneau F).




FIGURE B.1 – Synthèse globale du pipeline ML : Exécution budgétaire RDC (1996–2023). A : R^2 des trois modèles de régression (dépenses courantes, Random Forest meilleur à 0,445). B : F1-macro des trois classifieurs (Random Forest meilleur à 0,593). C : Importance SHAP, le lag d’exécution domine (42,3), trois fois le deuxième prédictor. D : Effets DML dépenses courantes, taux de change ($-0,239^{***}$) significatif. E : Effets DML dépenses en capital, efficacité gouvernementale ($+0,115^{**}$) significative. F : Score d’anomalie Isolation Forest, années 2000 (76,0), 1996 (68,8) et 2001 (52,2) détectées automatiquement comme les plus anormales, validant l’exclusion de la période hyperinflationniste. Source : calculs des auteurs.

DASHBOARD INTERACTIF STREAMLIT

Pour faciliter la réplication et l'exploration des résultats par des utilisateurs non techniques, un tableau de bord interactif a été développé avec la bibliothèque Streamlit (Python). Il implémente l'intégralité du pipeline ML01–ML04 dans une interface graphique accessible sans compétences en programmation.

Fonctionnalités principales

L'interface permet de :

- Filtrer les résultats par fonction budgétaire et par période d'analyse (1996–2023 ou sous-périodes).
- Visualiser l'évolution temporelle des taux d'exécution avec les seuils de régimes (80 % et 110 %), les annotations de ruptures structurelles et les marqueurs d'années électorales.
- Consulter les métriques de performance des modèles ML (régression ML01 et classification ML02) avec comparaison visuelle des trois algorithmes.
- Explorer les résultats DML (coefficients, intervalles de confiance, FDR) pour chaque traitement et chaque type de dépense.
- Exporter les résultats filtrés au format CSV.

Spécifications techniques

Le dashboard fonctionne localement sur Python 3.11 avec 4 Go de RAM minimum. Les données annuelles TOFE sont chargées depuis des fichiers CSV ; les modèles n'ont pas besoin d'être réentraînés à chaque mise à jour des données. Le code source et les instructions de déploiement sont disponibles dans le package de réplication accompagnant ce mémoire.

La Figure C.1 illustre l'interface de visualisation du tableau de bord, avec l'évolution temporelle des taux d'exécution et les annotations de ruptures structurelles.




FIGURE C.1 – Interface de visualisation du dashboard. Évolution temporelle des taux d'exécution par fonction budgétaire, avec seuils de régimes (zone grise = 80–110 %), annotations de ruptures structurelles et marqueurs d'années électorales. Les filtres mettent à jour tous les panneaux dynamiquement. Source : capture d'écran du dashboard de réplication.

La Figure C.2 présente l'interface de performance ML du tableau de bord, avec les métriques de régression (ML01) et de classification (ML02).

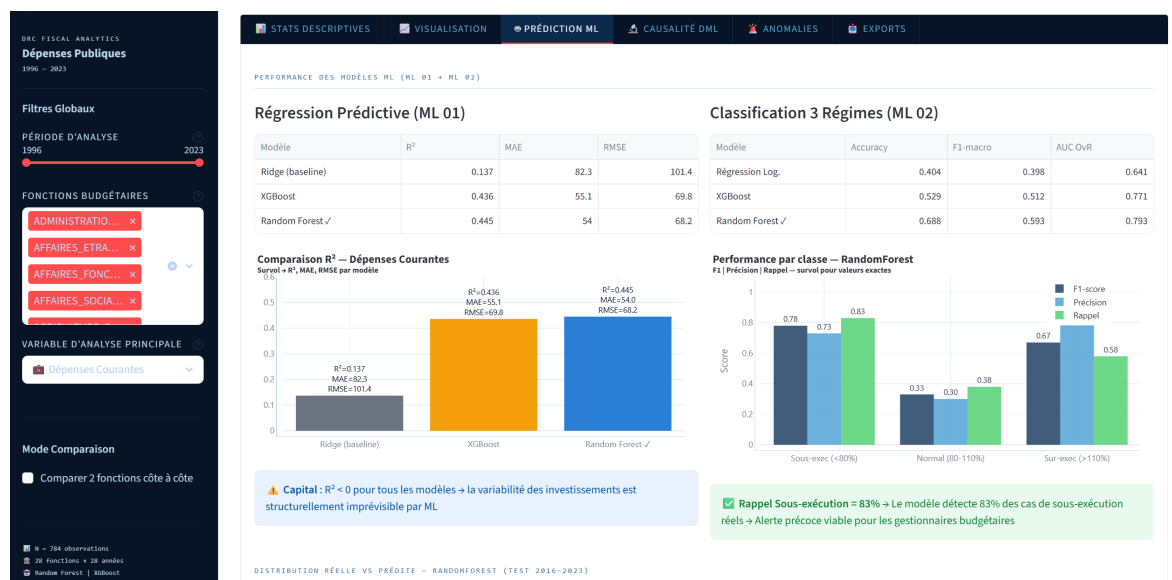


FIGURE C.2 – Interface de performance ML du dashboard. Gauche : métriques de régression (ML01), Random Forest atteint $R^2 = 0,445$, dépenses en capital imprévisibles ($R^2 < 0$). Droite : métriques de classification (ML02), accuracy 68,8 %, rappel 83 % sur la sous-exécution. Source : capture d'écran du dashboard de réplication.

QUYẾT ĐỊNH**Về việc thành lập Hội đồng đánh giá luận văn thạc sĩ****GIÁM ĐỐC ĐẠI HỌC QUỐC GIA HÀ NỘI**

Căn cứ Nghị định số 201/2025/NĐ-CP ngày 11 tháng 07 năm 2025 của Chính phủ quy định chức năng, nhiệm vụ và quyền hạn của đại học quốc gia;

Căn cứ Quyết định số 3636/QĐ-ĐHQGHN của Giám đốc Đại học Quốc gia Hà Nội ngày 21 tháng 10 năm 2022 của Giám đốc Đại học Quốc gia Hà Nội ban hành Quy chế đào tạo thạc sĩ tại Đại học Quốc gia Hà Nội;

Theo đề nghị của Hiệu trưởng Trường Quốc tế tại công văn số 1110/TQT-ĐT ngày 24 tháng 06 năm 2026 về việc đề xuất thành lập hội đồng đánh giá luận văn cho học viên;

Theo đề nghị của Trưởng ban Đào tạo và Công tác sinh viên.

QUYẾT ĐỊNH:

Điều 1. Thành lập Hội đồng đánh giá luận văn thạc sĩ của học viên cao học NZZI NGABILA Boaz, sinh ngày 06/01/1989, tại Công - gô;

Đề tài: Phân tích dự đoán và nhân quả về thực thi chỉ tiêu công tại CHDC Congo (1996 - 2023) bằng phương pháp Học máy;

Chuyên ngành: Hệ thống thông minh và Đa phương tiện; Mã số: 8480201.02;

Danh sách các thành viên của Hội đồng kèm theo Quyết định này.

Điều 2. Hội đồng có trách nhiệm đánh giá luận văn thạc sĩ theo Quy chế đào tạo thạc sĩ tại Đại học Quốc gia Hà Nội và tự giải thể sau khi hoàn thành nhiệm vụ.

Điều 3. Chánh Văn phòng, Trưởng ban Đào tạo và Công tác sinh viên, Hiệu trưởng Trường Quốc tế và các thành viên trong Hội đồng đánh giá luận văn thạc sĩ chịu trách nhiệm thi hành Quyết định này.

Nơi nhận:

- Như Điều 3;
- Giám đốc (để báo cáo);
- Lưu: VT, ĐT&CTSV, M10.

KT. GIÁM ĐỐC
PHÓ GIÁM ĐỐC



Đào Thanh Trường

DANH SÁCH HỘI ĐỒNG ĐÁNH GIÁ LUẬN VĂN THẠC SĨ

*(Kèm theo Quyết định số: 3218 /QĐ-ĐHQGHN, ngày 08 tháng 7 năm 2026
của Giám đốc Đại học Quốc gia Hà Nội)*

STT	Họ và tên	Ngành/ Chuyên ngành	Cơ quan công tác	Trách nhiệm trong Hội đồng
1	TS. Nguyễn Thị Minh Huyền	Công nghệ thông tin	Trường Đại học Khoa học Tự nhiên, ĐHQGHN	Chủ tịch
2	TS. Jean Tshibangu	Công nghệ thông tin	Trường kỹ thuật Leonard de Vinci (ESILV), CH. Pháp	Phản biện 1
3	TS. Sonfack Souchio Serge	Công nghệ thông tin	Đại học Joseph Ki- ZERBO, Burkina Faso	Phản biện 2
4	TS. Đào Tùng	Khoa học Quản lý	Trường quốc tế, ĐHQGHN	Thư ký
5	TS. Nguyễn Hồng Quang	Công nghệ thông tin	Hội Tin học Việt Nam (VAIP)	Ủy viên

Hội đồng gồm 05 thành viên.

Hanoi, le 21/07/2026

RESOLUTION DU JURY D'ÉVALUATION DE MÉMOIRE DE MASTER

Vu la Décision n°3218/QĐ-ĐHQGHN émise le 08/07/2026 par le Président de l'Université nationale du Vietnam, Hanoï, portant création du jury d'évaluation de mémoire de master pour évaluer le mémoire de master de l'étudiante **NZAZI NGABILA Boaz** (date de naissance : 06/01/1989)

Titre du mémoire : Analyse prédictive et causale de l'exécution des dépenses publiques en République démocratique du Congo (1996–2023) à l'aide de l'Apprentissage automatique

Spécialité : Systèmes intelligents et multimédia

Code : 8480201.02

Le jury d'évaluation de mémoire s'est réuni le 21/07/2026 à l'École internationale de l'Université nationale du Vietnam, Hanoï.

Après la présentation du mémoire par l'étudiant(e), des observations des rapporteurs, les commentaires des membres du jury et les réponses de l'étudiant(e), le jury a délibéré et a rendu sa décision:

1. La nécessité, la signification scientifique et l'aspect pratique du sujet de mémoire

La nécessité de ce mémoire réside dans le fait que l'exécution des dépenses publiques en RDC reste marquée par une forte instabilité institutionnelle, économique et politique, ce qui exige des outils analytiques capables de dépasser les approches classiques. Sur le plan scientifique, le travail apporte une contribution originale en combinant prédiction et causalité par apprentissage automatique, comblant ainsi une lacune dans la littérature qui confond souvent ces deux dimensions. Il met en évidence des mécanismes causaux robustes et reproductibles, offrant une avancée méthodologique pour l'étude des finances publiques dans les États fragiles. Sur le plan pratique, ce mémoire propose un cadre opérationnel pour anticiper les risques de sous-exécution budgétaire et formuler des recommandations de politique publique fondées sur des preuves causales, utiles aux décideurs congolais et aux partenaires internationaux.

2. Structure, méthodologie de recherche, références, etc., du mémoire



La structure du mémoire est organisée de manière claire et progressive, allant du contexte et de la problématique jusqu'aux résultats et recommandations. La méthodologie repose sur un pipeline analytique intégrant prédiction, classification, interprétation et inférence causale, avec des outils comme Random Forest, XGBoost, SHAP et Double Machine Learning. Les données proviennent principalement des rapports de la Banque Centrale du Congo, complétées par celles du FMI et de la Banque mondiale, puis validées par un panel externe sur l'Angola. Les références bibliographiques sont variées et couvrent à la fois la littérature en finances publiques et en intelligence artificielle, assurant une assise scientifique solide.

3. Résultats de la recherche:

Les résultats principaux du mémoire confirment que les objectifs fixés ont été atteints. Les dépenses courantes se révèlent prévisibles grâce aux modèles d'apprentissage automatique, tandis que les dépenses en capital échappent à la prédiction, révélant leur dépendance à des facteurs externes. L'approche causale a permis d'identifier des mécanismes robustes expliquant l'exécution budgétaire, validés partiellement dans un autre contexte africain. Ces résultats apportent à la fois une avancée scientifique et des outils pratiques pour améliorer la gestion des finances publiques en RDC.

4. Limitations et demandes de correction du mémoire (le cas échéant)

Les limites du mémoire concernent principalement la description des données, qui doit être davantage détaillée et clarifiée. La présentation méthodologique nécessite aussi quelques ajustements pour renforcer la cohérence et la lisibilité du travail. Enfin, certains aspects de forme, tels que la structuration et la mise en page, doivent être améliorés. Le jury demande que ces corrections soient intégrées dans la version révisée du mémoire.

5. Évaluation globale:

Le jury vous félicite pour la qualité générale de votre travail et de votre soutenance, en particulier pour les deux publications réalisées. Le jury reconnaît la pertinence de la problématique, l'intérêt scientifique de votre sujet ainsi que l'effort fourni dans vos analyses. Toutefois, il vous est demandé d'apporter certaines corrections et améliorations au mémoire, notamment concernant la description des données, la présentation méthodologique et quelques aspects de forme. Vous devriez intégrer les remarques des membres du jury dans la version corrigée de votre mémoire. Globalement, votre soutenance est jugée satisfaisante.

Note du mémoire: 8.2/10

Résultat de la soutenance de mémoire de master de l'étudiant 8.2/10

Admis : ☒

Non admis : ☐

(Le mémoire est admis si la note moyenne attribuée par le jury est de 5,5 ou plus).

Cette résolution est adoptée à l'unanimité par 05/05 membres du jury.

SECRETAIRE DU JURY




Dr. Đào Tùng

PRESIDENT DU JURY



Dr. Nguyễn Thị Minh Huyền

**Certification de l'Ecole innationale
P.P. RECTEUR
DEPARTEMENT DE SCOLARITE**



Prof. Assoc. Dr. Hoàng Tuyết Minh



BẢN XÁC NHẬN/ATTESTATION
Về việc chỉnh sửa luận văn thạc sĩ sau bảo vệ
De la correction du mémoire après la soutenance

Họ và tên/*Nom et prénom*: **NZAZI NGABILA Boaz**
Lớp/*Classe*: P27 SIM
Khóa/*Promotion*: QH - 2023
Chuyên ngành/*Parcours*: Hệ thống thông minh và Đa phương tiện/*Systèmes Intelligents et Multimédia*
Ngày bảo vệ/*Date de soutenance*: 21/07/2026
Đề tài luận văn/*Sujet de mémoire*:
- Tiếng Việt/*En vietnamien*: **PHÂN TÍCH DỰ ĐOÁN VÀ NHÂN QUẢ VỀ THỰC THI CHI TIÊU CÔNG TẠI CHDC CONGO (1996–2023) BẰNG PHƯƠNG PHÁP HỌC MÁY**
- Tiếng Pháp/*En français*: **ANALYSE PRÉDICTIVE ET CAUSALE DE L'EXÉCUTION DES DÉPENSES PUBLIQUES EN RDC (1996–2023) PAR APPRENTISSAGE AUTOMATIQUE**
Giáo viên hướng dẫn/*Encadrant*: Pr. Dr. Selain Kasereka Kabunga
Thời gian bảo vệ luận văn/*Date de soutenance*: 21/07/2026
Sau khi bảo vệ luận văn, được sự góp ý của Hội đồng chấm luận văn thạc sĩ, tôi đã chỉnh sửa và hoàn chỉnh luận văn theo các vấn đề sau/*Après avoir soutenu le mémoire, avec des remarques du Jury d'évaluation du mémoire, j'ai corrigé et achevé mon mémoire pour les points ci-dessous*:

STT	Nội dung góp ý của hội đồng <i>Remarques du Jury</i>	Nội dung đã chỉnh sửa <i>Contenu corrigé</i>	Mục/Trang đã chỉnh sửa/ <i>Chapitre/page corrigé(e)</i>
1	Description du jeu de données incomplète ; gestion des données manquantes.	Ajout d'un dictionnaire complet des variables et d'une sous-section Gestion des données manquantes (mécanismes MNAR/MAR, justification du non-recours à l'imputation, impact sur C3/C4).	Chap. 3, §3.5–3.6 (Données) Page 44 à 50
2	Éléments complémentaires d'évaluation manquants, notamment la matrice de confusion.	Ajout de la matrice de confusion 3×3 du Random Forest, avec analyse du rappel, de la précision et des confusions entre classes.	Chap. 4, §4.3 (ML02) Page 62 à 63

3	Discussion des hypothèses et limites de l'inférence causale trop brève ; impact sur les résultats non précisé.	hypothèse d'exogénéité conditionnelle, endogénéité et faible variation du WGI (C4), échantillon réduit sur le capital, et effet chiffré de ces limites sur C3/C4.	Chap. 4, §4.11 Page 74 à 73
4	Reproductibilité à renforcer ; recommandations à rendre plus opérationnelles.	Ajout du lien vers le dépôt GitHub (données + code + graine 42)	Chap. 3, §3.14.1 Page 58
5	Recommandations concrètes plus	Recommandations précisées par mécanisme (acteur, instrument existant, coût), adaptées au contexte congolais.	Conclusion générale, §3 Page 79

Hà Nội, ngày 28 tháng 07 năm 2026

XÁC NHẬN CỦA GIÁO VIÊN HƯỚNG DẪN
APPROBATION DE L'ENCADRANT



HỌC VIÊN
ÉTUDIANT



NZAZI NGABILA Boaz

XÁC NHẬN CỦA CHỦ TỊCH HỘI ĐỒNG
APPROBATION DU PRÉSIDENT DU JURY



Nguyễn Thị Minh Huyền

CỘNG HÒA XÃ HỘI CHỦ NGHĨA VIỆT NAM
Độc lập – Tự do – Hạnh phúc/
SOCIALIST REPUBLIC OF VIETNAM
Independence – Freedom – Happiness

GIẤY THỎA THUẬN/ AGREEMENT LETTER
V/v Sử dụng, khai thác nội dung tài liệu nộp lưu chiểu/
Regarding the use and exploitation of submitted archival documents

Tôi tên là/ *Full name*: **NZAZI NGABILA Boaz** Số điện thoại/ *Tel*: +243 82 30 87 047

Là tác giả tài liệu/*As the author of the document*:

Phân tích dự đoán và nhân quả về thực thi chi tiêu công tại chdc congo (1996–2023)
bằng phương pháp học máy / Predictive and causal analysis of public expenditure
execution in the dr congo (1996–2023) using machine learning methods

Tôi làm bản thỏa thuận này với Thư viện Trường Quốc tế như sau/ *I make this agreement with the VNU-IS Library as follows*:

Tôi đồng ý cho phép Thư viện Trường Quốc tế sử dụng và khai thác nội dung tài liệu vào mục đích phục vụ nghiên cứu khoa học, giảng dạy và học tập trong ĐHQGHN/ *I agree to allow the VNU-IS Library to use and exploit the content of the documents for the purposes of scientific research, teaching, and learning within the Vietnam National University./.*

Hà Nội, ngày 3 tháng 08 năm 2026

Tác giả/ *Author*

(Ký và ghi rõ họ tên/*Full name and signature*)



NZAZI NGABILA Boaz