

Évaluation économique de vérification ciblée par intelligence artificielle des Centres de Santé de Base bénéficiaires du financement basé sur la performance

F. E. Rabearitsoa¹, C. DIZEYE², F. M. Randriatsarafara³, M. A. Rakotomalala⁴

1. RABEARITSOA Florent Eric, doctorant à l'Université d'Antananarivo, école doctorale Sciences et Techniques de l'Ingénierie et de l'Innovation (STII), EAD : Réseaux, Intelligence artificielle, Multimédia, Sécurité et Système d'informations (RIMSS), École Supérieure Polytechnique d'Antananarivo

2. Dr. Cédric DIZEYE, économiste principal en santé de la Banque mondiale, Antananarivo

3. RANDRIATSARAFARA Fidiniaina Mamy, professeur agrégé à la faculté de médecine de l'Université d'Antananarivo

4. RAKOTOMALALA Mamy Alain, professeur à l'École Supérieure Polytechnique d'Antananarivo, école doctorale STII, EAD/RIMSS

Auteur correspondant : RABEARITSOA Florent Eric, Antananarivo (101), Madagascar

mail : eric.rabearitsoa2@gmail.com , WhatsApp : +261341281751

RÉSUMÉ

L'intelligence artificielle (IA) a considérablement transformé le secteur de la santé, pourtant son utilisation dans le contexte du financement basé sur la performance (FBP) est très peu documentée. Cette étude vise à optimiser les coûts du mécanisme de vérification du FBP par l'intelligence artificielle en ciblant les Centres de santé de base frauduleux.

Cette étude propose d'utiliser le modèle XGBoost pour cibler les CSB à risque de fraudes, en intégrant les compromis décisionnels basés sur l'optimisation du seuil de décision, afin d'assurer un équilibre entre sensibilité et spécificité.

À une valeur optimale proche de 0,19 du seuil de décision, les bénéfices générés par l'IA sont maximaux pour les 25 CSB. L'IA permet de gagner \$145 963 par District pour la vérification des données, en réduisant jusqu'à 25% les coûts de vérification (ratio du coût résiduel). Le TPR économique de la vérification ciblée par l'IA est de 86%. L'IA permet de réduire à moins de 20% le nombres des CSB à auditer.

Cette étude vise à améliorer l'efficacité du mécanisme de vérification du FBP par l'utilisation de l'IA. Elle contribue à optimiser l'allocation des ressources publiques du financement de la santé publique.

Mots-clés

Achat stratégique du secteur sanitaire, Économie de la santé, Financement basé sur la performance, XGBoost.

ABSTRACT

Artificial Intelligence has changed the healthcare sector a lot. We do not know much about how it is used with Performance-Based Financing (PBF). This study wants to use Artificial Intelligence to make the process of checking data and finding fraud better at Primary Health Centers (PHC) that're part of PBF.

This study proposes the use of XGBoost to identify the top 20% of PHC at risk of fraud, incorporating decision-making trade-offs through the optimization of the classification threshold, in order to ensure a balance between sensitivity and specificity.

The results indicate that the optimal decision threshold is approximately 0,19. At this threshold, the benefits generated by the AI are maximized for a health district comprising 25 PHC. Over a 12-quarter period of performance-based financing activities, the AI enables savings of \$145963 per district for the verification of data, reducing verification costs by up to 25% (residual cost ratio). The economic true positive rate of the targeted verification is 86%. Reducing the proportion of fraudulent PHC to be audited to less than 20% enables optimization of logistical resources at the health district level.

This study aims to improve the efficiency of the PBF verification mechanism by leveraging AI to reduce operational costs and the logistical constraints inherent in PBF verification processes. This work contributes to optimizing the allocation of public resources dedicated to PBF.

Keywords

Performance-based financing (PBF), Strategic health purchasing, XGBoost, Health Economics

I. INTRODUCTION

Le financement basé sur la performance (FBP) en tant que réforme de la gestion de ressources publiques, vise essentiellement à rendre plus efficient le financement de la santé publique. À Madagascar depuis 2013, plusieurs Centres de santé de base (CSB) sont sous contrat du FBP. Ce mécanisme repose sur l'achat stratégique de performance réelle des formations sanitaires [1]. L'achat de performance des indicateurs sanitaires des CSB repose sur la vérification, ou audit des données sanitaires déclarées. Ce mécanisme de vérification systématique garantit la fiabilité des indicateurs sanitaires déclarés objet d'achat. Ce mécanisme limite les risques de comportements frauduleux des prestataires, car il implique également des enquêtes auprès des usagers, afin de confirmer la véracité de la prestation de soins offerte. Ce mécanisme est plus sûr pour lutter contre les fraudes des CSB [2]. Pourtant il nécessite une mobilisation de ressources importantes. La fraude de performance

consiste à créer des usagers fictifs, ou falsifier les données sanitaires afin d'augmenter les primes du personnel.

L'avancée majeure de l'intelligence artificielle (IA) a permis de développer considérablement la lutte contre les fraudes dans différents domaines. Et la détection de façon précoce de certaines anomalies des données est une piste permettant d'orienter à la détection de risque de cas de fraudes [3,4].

L'utilisation de l'apprentissage supervisé dans le domaine du FBP du secteur sanitaire est peu documenté, cependant son utilisation est une piste pour réduire le coût de la vérification externe des données des CSB, en limitant l'audit ou la vérification des données aux CSB à risque de fraude. Cette étude a utilisé le modèle d'apprentissage supervisé *XGBoost*, pour cibler les CSB frauduleux du FBP, et évaluer l'impact économique de l'utilisation de l'IA dans le système de vérification externes des données.

Ce travail s'inscrit dans le cadre de l'économie de la santé, et de l'intelligence artificielle appliquée, qui vise à optimiser l'efficacité du FBP.

II. RAPPEL SUR LE CYCLE D'ACHAT DE PERFORMANCE DES CSB

Le rythme trimestriel est le modèle de vérification des données des CSB adopté par le projet PARN à Madagascar. Cette vérification est suivie d'une évaluation de la qualité de service, et finalement d'une enquête auprès des usagers de chaque CSB.

a) *Vérification des données*

C'est la vérification des indicateurs sanitaires, ou audit des données qui est réalisée systématiquement par une équipe externe pour auditer les données des CSB avant l'achat de performance.

b) *Enquête auprès des usagers de CSB*

L'enquête auprès des usagers a pour objectifs de vérifier la véracité de prestation de soins enregistrés dans les CSB, et évaluer la satisfaction des usagers. Pour la vérification de prestation, elle a permis de classer les CSB en : (1) **CSB fraudeurs** par création des usagers fictifs, (2) **CSB fortement suspects de fraudes**, et (3) **CSB conformes**.

c) *Définition opérationnelle*

***Fraude :** on entend par fraude des formations sanitaires sous contrat de performance «la création d'utilisateurs de service fictifs, la mention d'actes ou de soins dont l'utilisateur de service n'a pas réellement bénéficié, la constatation de tout acte de malversation et de manipulation des données sanitaires. »*

Cas suspect de fraude :

- Dans le cadre de la vérification des données ou de l'évaluation de la qualité, un cas suspect de fraude est défini comme « la constatation sur les supports de collecte des données et dossiers

médicaux au cours d'une activité (curative, préventive ou promotionnelle) d'une écriture différente, de l'utilisation de stylo de tonalité ou de couleur différente, des ratures intempestives, l'utilisation anarchique de correcteur ».

- Lors de l'enquête communautaire, un cas est suspect de fraude si la discordance entre les motifs d'utilisation de service déclarés par usagers et les motifs de service enregistrés dans les registres des données est supérieure à 10 % de l'échantillon. Cette variable d'enquête reflète la qualité de collecte des données sanitaires, mais la réponse des usagers est fortement influencée par le biais de mémoire, le niveau d'instruction et l'insuffisance de communication claire entre les patients et les prestataires de soins.

Le schéma ci-dessous illustre le cycle trimestriel d'achat de performance des CSB.




Figure N° 1 : Cycle trimestriel d'achat de performance des CSB à Madagascar

III. OBJECTIFS DE L'ÉTUDE

- L'objectif général consiste à réduire le coût de la vérification classique des CSB du FBP.
- Les objectifs spécifiques consistent à :
 - utiliser le modèle de classification XGBoost pour cibler les CSB frauduleux ;
 - réduire à moins de 25% le nombre de CSB à vérifier ;
 - évaluer l'impact économique de la vérification ciblée par l'IA.

IV. REVUE DE LITTÉRATURE

a) Modèle d'extreme gradient boosting (XGBoost)

Définition

Selon l'étude réalisée par (Chen et al, 2016) [5] l'Extreme Gradient Boosting (XGBoost) est un algorithme d'apprentissage supervisé fondé sur le gradient boosting, conçu pour être hautement performant, efficace et scalable. Il optimise une fonction de perte différentiable par descente de gradient en espace fonctionnel, en combinant séquentiellement des arbres de décision régularisés. Le modèle introduit des mécanismes avancés tels que la régularisation explicite (L1/L2), l'élagage automatique de la taille des arbres de décision, la gestion native des valeurs manquantes et une implémentation parallèle optimisée, le rendant adapté aux très grands jeux de données. Le XGBoost utilise le modèle mathématique de type additif.

Soit un jeu de données d'apprentissage ci-dessous :

- $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, avec $x_i \in \mathbb{R}^d$, y_i est une variable cible (binaire, continue ou muticlasses).

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i)$$

où :

- F est l'ensemble des fonctions représentables par des arbres de la « Classification And Regression Trees » ou CART,
- $f_k \in F$, et f_k est un arbre de décision (fonction de *partition* de l'espace),
- K est le nombre total d'arbres (boosting rounds),
- $\hat{y}_i$ est la prédiction du modèle pour l'observation x_i .

b) Return on Investment (ROI)

Définition

Selon la définition du (Corporate Finance Institute, 2023) [6], « *Le retour sur investissement (ROI) est une mesure de performance utilisée pour évaluer l'efficacité ou la rentabilité d'un investissement. Il compare le gain ou la perte générée(e) par rapport au coût de l'investissement.* »

c) Le taux de réduction des coûts

Selon les principes de l'(OCDE, 2018) [7], et de la (Banque mondiale, 2016) [8], c'est un indicateur de performance mesurant la proportion d'économies réalisées par rapport à un scénario de référence.

d) Efficience

Selon (Farrell, 1957) [9], elle est définie comme la capacité d'une unité de production à obtenir le maximum d'output pour un niveau donné d'inputs, ou inversement à utiliser le minimum d'inputs pour produire un niveau donné d'output.

V. MÉTHODOLOGIE

La méthodologie adoptée est de type hybride IA appliquée, et économie de la santé, elle est dynamique, et sensible au seuil de précision ou probabilité de fraude, en visant une prise de décision optimale. Elle est validée en conditions réelles de 25 CSB publics sous contrat de performance du District sanitaire d'Ambatolampy.

1) Performance du modèle XGBoost utilisé

Nous avons utilisé le modèle d'apprentissage supervisé XGBoost, pour la classification des CSB frauduleux du financement basé sur la performance.

L'analyse de performance du XGBoost est axé sur l'approche coût, et les compromis (Faux Positifs vs Faux Négatifs). Le coût des Faux Positifs (FP) représente le coût opérationnel de vérification inutile par fausse alerte (coût moyen FP : \$ 53 par CSB *source projet PARN/FBP Madagascar*). Le coût des Faux Négatifs (FN) représente le coût de perte financière liée au fonds de sanction non récupéré d'un CSB frauduleux non détecté (coût moyen FN : \$ 348 par CSB frauduleux non détecté, *source projet PARN/FBP Madagascar*).

a) Source des données

- Données de 25 CSB publics du District sanitaire d'Ambatolampy de 2019 à 2021 :
 - données des 11 enquêtes trimestrielles auprès des usagers (échantillonnage aléatoire stratifié, dont la taille d'échantillon est de 5% de la fréquentation globale du CSB de la période vérifiée) ;
 - données vérifiées ou auditées des CSB par des équipes externes ;
 - Scores d'évaluation de la qualité de service des CSB ;
- Données issues du système national d'information sanitaire (2019-2021).

Les sources de données sont des données internes du FBP à Madagascar, non exploitées dans le processus d'entraînement des modèles d'intelligence artificielle.

b) Variables

Variable cible : fraude (Oui / Non), sources : Enquête de fraudes des CSB auprès des usagers (2019-2021)

Variables explicatives (Features)

- Proportion de fréquentation mensuelle du CSB [fréquentation/ (population annuelle/12)] ;
- Score LOF moyen, k de voisinage plus proches : $5 \leq k \leq 12$;
- Proportion de fréquentation moyenne mensuelle du District ;
- Score de qualité de Service du CSB ;
- Activité de soins de proximité ;
- Population du secteur sanitaire du CSB ;
- Distance entre le CSB et le District ;
- Nombre de Fokontany ;
- Nombre de villages ;
- Classement d'habitation de la population selon la distance par rapport aux CSB (1 à 3) ;
- Densité de la population par Village ;
- Trimestre d'évaluation (1 à 4) ;
- Mois d'évaluation (1 à 12).

Les variables explicatives ont été sélectionnées afin de capturer trois dimensions complémentaires de la détection de fraude :

- les anomalies des données ;
- la répartition géographique de la population desservie ;
- et les contraintes d'accessibilité du CSB.

Cette approche permet d'intégrer à la fois des indicateurs de performance, avec analyse des anomalies, indicateurs comportementaux, spatiaux, offrant ainsi une modélisation robuste de classification des fraudes.

Prétraitement

- Traitement des données utilisées ;
- Division des données (80% entraînement - 20% test)

c) Entraînement du modèle XGBoost

- Optimisation par les métriques clés (AUC, F2-score, coût attendu) ;
- Validation croisée ;
- Le modèle utilisé est déjà validé par des données externes des sources de données d'entraînement et de test, en utilisant les données sanitaires des 22 CSB du district sanitaire d'Antanifotsy.

Résultat attendu de la performance du XGBoost :

- Prévalence de fraudes des CSB de la période (2019-2021) du district d'Ambatolampy

Prédiction de fraudes des CSB

- *Probabilité de fraude pour chaque CSB*
- *Application d'un seuil de décision (t) : courbes de compromis décisionnel (sensibilité vs spécificité), et (cas faux positifs vs faux négatifs du jeu de test).*

2) Simulation économique basée sur le seuil

La simulation économique est réalisée à partir des performances observées sur le jeu de test (sensibilité et spécificité) du modèle XGBoost, puis extrapolé à une population de 25 CSB. La prévalence moyenne utilisée (14%) est celle du District sanitaire d'Ambatolampy durant la période d'enquête auprès des usagers (2019-2021). les coûts utilisés sont des couts moyens opérationnels de la mise en œuvre du FBP.

a) Fonction de bénéfice généré par l'IA (B_{IA})

$$B_{IA}(t) = (TP * V_{TP}) + (TN * V_{TN}) - (FP * C_{FP}) - (FN * C_{FN})$$

Selon (F. Provost et al, 2013) [10], c'est la somme pondérée des résultats de la matrice de confusion par leurs coûts/bénéfices.

$B_{IA}(t)$: Bénéfices générés par l'IA en fonction du seuil de décision pour évaluation de 25 CSB

- $TP * V_{TP}$: Valeur de coûts épargné grâce à la détection des CSB frauduleux, sous forme de sanction pécuniaire ($V_{TP} = \$348$ par CSB) ;
- $TN * V_{TN}$: Valeur des coûts de vérification évités grâce à l'identification correcte des CSB conformes ($V_{TN} = \$53$ par CSB conforme, coût de vérification d'un CSB) ;
- $FP * C_{FP}$: Coût des faux positifs ou verification inutile déclenché par les fausses alertes ($C_{FP} = \$53$, coût de vérification d'un CSB) ;
- $FN * C_{FN}$: Coût des faux négatifs, ($C_{FN} = \$348$ par cas de CSB frauduleux non détecté, sanction pécuniaire non appliquée).

résultats économiques attendus :

- *Courbe d'évolution des bénéfices générés par l'IA en fonction du seuil de décision pour 25 CSB ;*
- *variation du seuil $t \in [0,1]$;*
- *calcul du gain pour chaque seuil ;*
- *calcul de gain maximum pour les 25 CSB*
- *Identification du seuil de décision optimal.*

3) Indicateurs d'évaluation économique

a) Projection des coûts de vérifications des données de 25 CSB pour une période 12 trimestres

- C_0 : Coûts réels observés de vérification classique des CSB (fonctionnement et investissement) ;
- C_{IA} : Projection des coûts de vérification ciblée des CSB orientée par l'IA basé sur les coûts réel de fonctionnement et d'investissement, et calculé sur la base d'une hypothèse de réduction à 20% le nombre de CSB à vérifier.

Les indicateurs économiques sont calculés sur base d'une période de 12 trimestres d'activités de 25 CSB dans le District d'Ambatolampy, correspond à 12 achats trimestriels réalisés. Cette période 12 trimestres correspond à la durée de la mise en œuvre du FBP d'une phase du Projet d'Amélioration des Résultats Nutritionnels PARN (projet multi phase). Les données financières utilisés dans cette étude sont des coûts réels de la phase I et II du projet PARN.

Formules des indicateurs économiques

Indicateur	mode de calcul
Économie (E)	$(C_0 - C_{ia})$
Gain net (12 achats)	$(C_0 - C_{ia}) + B_{(IA)} * 12$
Taux de réduction des coûts	$(C_0 - C_{ia}) / C_0$
Ratio du coût résiduel	C_{ia} / C_0
Facteur d'efficience	C_0 / C_{ia}
ROI opérationnel	$(Économie / C_{ia}) * 100$

Nb : $B_{(IA)} * 12$ (projection de bénéfices générés par IA pour 12 trimestres d'achat de performance de 25 CSB)

✓ **Économie réalisée** $E = C_0 - C_{ia}$

L'économie directe générée par l'utilisation de l'intelligence artificielle, c'est la différence entre le coût de vérification classique du FBP et le coût optimisé utilisant l'IA. L'économie directe est calculée sur base des coûts d'investissement et de fonctionnement d'un district sanitaire de 25 CSB. L'indicateur mesure la simulation d'économie moyenne de 12 trimestres d'activités du FBP pour un District sanitaire. Les projections reposent sur une hypothèse de diminution de 20 % de nombre de CSB à vérifier par IA.

✓ **Retour sur investissement (ROI) opérationnel**

$$ROI = \left(\frac{E}{C_{ia}} \right) \times 100$$

Le ROI opérationnel permet d'évaluer la rentabilité d'une amélioration opérationnelle de la vérification ciblée des 25 CSB pour 12 achats de performance en utilisant l'IA.

$$✓ \text{ Taux de réduction des coûts} = \frac{C_0 - C_{ia}}{C_0}$$

Cet indicateur exprime la proportion de réduction des coûts obtenue entre la vérification classique et la vérification ciblée par l'IA.

$$✓ \text{ Gain net : } (C_0 - C_{ia}) + B_{(IA)} * 12$$

Il mesure la projection de gain total pour 12 cycles d'achat de performance de 25 CSB dans un District sanitaire. Le gain net représente l'économie liée à l'investissement, au fonctionnement du nouveau système de vérification, plus les gains générés par l'IA pour 12 vérifications ciblées des CSB ($B_{(IA)} * 12$).

Résultat attendu :

- Économie (E) d'utilisation de l'IA ;
- Gain net (12 achats) d'utilisation de l'IA ;
- Taux de réduction des coûts ;
- Ratio du coût résiduel ;
- Facteur d'efficience ;
- ROI opérationnel.

b) Apprentissage sensible aux coûts

- TPR économique
- FPR économique

4) Logiciels utilisés :

- RStudio version : 2026.01.1.403, R version : 4.5.2
- Excel pour le stockage des données (csv)

VI. RÉSULTATS

A. PRÉVALENCE DE FRAUDE DES CSB DU DISTRICT D'AMBATOLAMPY

Tableau 1 : Prévalence de fraude des CSB du district d'Ambatolampy (2019-2021)

Enquête CSB	Proportion
CSB Fraudeurs	14%

CSB Conformes	86%
---------------	-----

Les résultats d'enquêtes montrent une prévalence de fraude qui a varié de [0%-20%], dont la prévalence moyenne a été de 14%.

B. PERFORMANCE DU XGBOOST POUR CLASSIFICATION DE FRAUDE DES CSB

a) Principales métriques de performance du XGBoost




Figure 1 : Performance du modèle XGBoost

Hyperparamètres d'entraînement du modèle XGBoost :

- nombre maximal d'itérations (nrounds : 300), le nombre optimal a été déterminé par un mécanisme d'arrêt anticipé (early stopping) basé sur l'AUC maximale observée ;
- validation croisée stratifiée à 5 plis (nfold : 5) ;
- paramètre adapté au déséquilibre (métrique d'évaluation : AUC) ;
- contrôle du surapprentissage par une profondeur limitée des arbres (max_depth = 3);
- apprentissage progressif grâce à un faible taux d'apprentissage (eta = 0,04) ;
- seuil de décision (0,19).

b) compromis décisionnel basé sur la sensibilité et la spécificité du modèle XGBoost




Figure 2 : Courbes de compromis décisionnel de sensibilité et de spécificité aux fraudes

c) compromis décisionnel basé sur le nombre de cas faux positifs et faux négatifs




Figure 3: Courbes de compromis décisionnel de faux négatifs et faux positifs

d) Importance des variables prédictives




Figure 4 : Graphique d'importance des variables prédictives dans la classification de fraude des CSB par le modèle XGBoost

e) validation externe

Le nombre de Centres de santé de base à cibler par l'IA est limité à 5 sur 22 CSB du district d'Antanifotsy.

Données de référence sur les fraudes des CSB :

- Résultats d'enquête trimestrielle auprès des usagers de 22 CSB du district d'Antanifotsy ;
- Taille d'échantillon d'enquête (1133 usagers), date d'enquête (Novembre 2024), période T1/2024.

Tableau 2 : Résultats de validation externe

Classification de fraude	CSB fraudeur	CSB suspect
Prédiction du XGBoost (limitée à 5 CSB)	2	3
Résultats d'enquête auprès des usagers	2	5

C. SIMULATION DES BÉNÉFICES GÉNÉRÉS PAR L'IA EN FONCTION DU SEUIL DE DÉCISION




Figure 5 : Évolution des bénéfices générés par l'IA en fonction du seuil de décision

Tableau 3 : Gain économique maximal généré par l'IA au seuil de décision optimal avec IC95%

Gain maximal	IC 95 % (Bootstrap)	Seuil optimal
1696,745 \$	[1225.17 ; 2082.87]	0,19

Les intervalles de confiance à 95 % ont été estimés par la méthode du bootstrap (1000 réplifications).




Figure 6 : Sensibilité du gain économique en fonction de la prévalence de la fraude

Projection des coûts de vérifications des données de 25 CSB pour une période 12 trimestres

- C_O : Coûts réels observés de verification classique des CSB ;
- C_{IA} : Projection des coûts de verification ciblée des CSB orientée par l'IA.

Nb : Coûts basé sur le fonctionnement et l'investissement lié à la vérification.

Tableau 4 : Coûts de vérifications classique et coûts de verification ciblée des CSB par l'IA

Cout d'évaluation classique (C_O)	Cout d'évaluation ciblée par IA Xgboost (C_{ia})	Économie absolue (E)
\$168 153	\$42 551	\$125 602

Taux de change utilisé par le projet PARN II pour la budgétisation 1 IUS \$=4200 Ariary

Source : Plans de travail budgétisés annuels PARN MinSP/DGMP/CCTN-FBP

D. INDICATEURS D'ÉVALUATION ÉCONOMIQUE

1) Indicateurs de performance économique et d'efficience du système de vérification ciblée par IA des 25 CSB

Tableau 5 : Indicateurs de performance économique et d'efficience de vérification ciblée des CSB

Indicateur	Résultat (\$)
Économie (E)	\$ 125 602
Gain net de vérification ciblée par IA	\$145 963
Taux de réduction des coûts	75%
Ratio du coût résiduel	25%
Facteur d'efficience	4
ROI opérationnel	295%

NB :

- $B_{(IA)}$ utilisé est le bénéfice maximum de US \$ 1696,7 pour une période trimestrielle d'évaluation des 25 CSB.
- Le calcul est basé sur les 12 trimestres d'activité du FBP du projet PARN II -FBP (12 achats de performance).

2) Indicateurs d'apprentissage sensible au coût (Cost-sensitive learning)

Le tableau ci-après présente les résultats des indicateurs d'apprentissage sensible au coût pour les 25 CSB du district sanitaire d'Ambatolampy, en utilisant le modèle XGBoost pour la perte de fraudes des 25 CSB.

Tableau 6 : Indicateurs d'apprentissage sensible au coût du modèle de XGBoost

Modèle XGBoost	
TPR économique	86%
FPR économique	4%

VII. DISCUSSION

A. Analyse de performance du modèle XGBoost pour classification de fraude des CSB

Le choix d'optimisation du modèle intègre le cadre sensible aux coûts des erreurs, car le coût d'un faux négatif est six fois plus du coût d'un faux positif ou fausse alerte. Le coût moyen d'un cas de faux négatifs est estimé à 348 \$, selon le coût réel de la mise en œuvre du FBP à Madagascar. Ce coût représente le coût moyen de sanction financière non récupéré d'un CSB frauduleux. Le coût d'une fausse alerte ou un faux positif est estimé à 53 \$. Le compromis décisionnel du seuil de décision doit intégrer cette asymétrie des coûts des erreurs. Le modèle doit minimiser le coût total lié aux faux positifs, et aux faux négatifs. La sensibilité aux fraudes doit être au maximum possible afin de limiter les faux négatifs. Et la spécificité doit être élevée pour minimiser au maximum les faux positifs.

L'analyse de deux courbes de compromis décisionnel montrent que le seuil de décision optimal est compris entre [0,12-0,19], afin d'optimiser la sensibilité et la spécificité. Ce seuil permet d'obtenir le meilleur compromis entre sensibilité et spécificité (M. D. Ruopp et al, 2028) [11].

Les hyperparamètres retenus visent à optimiser les performances prédictives du XGBoost permettant à assurer la robustesse, la stabilité du modèle face au déséquilibre des données et à limiter le risque de surapprentissage [nombre maximal d'itérations : 300, validation croisée stratifiée à 5 plis, métrique d'évaluation par AUC, contrôle du surapprentissage par une profondeur limitée des arbres à trois niveaux (max_depth : 3), apprentissage progressif grâce à un faible taux d'apprentissage d'eta : 0,04]. Concernant l'importance des variables prédictives dans la classification de fraude des CSB, la fréquentation, les soins de proximité, la période, la qualité de service et les scores LOF des données aberrantes présentent une contribuent importante à la classification.

Les résultats de la validation des données externes montrent que le modèle a détecté les deux cas frauduleux, et les trois cas suspects. Les cas suspects sont à traiter avec prudence car ils sont très influencés par deux biais :

- « *le biais de mémoire de la personne interviewée* », car l'enquête a été réalisée sept mois après la prestation de service ;

et « *le biais en rapport avec le niveau d'instruction* », de la population rurale à Madagascar. Les résultats d'enquête permanente auprès des ménages (EPM) en (2021-2022), de l'INSTAT [12] confirment que 21% de la population n'a aucun niveau d'instruction, et 44,3% de la population a un niveau primaire. Pourtant les 3 cas suspects de fraudes détectés par XGBoost signifient que les données sanitaires de ces trois CSB sont en faveur d'un risque élevé de fraude.

B. Simulation des bénéfices générés par l'IA en fonction du seuil de décision

Le bénéfice maximum généré par l'IA pour une évaluation trimestrielle d'un District sanitaire de 25 CSB, comme le cas du District d'Ambatolampy est estimé à US \$ 1697. Dont le seuil optimal de décision est égal à 0,19. Ce bénéfice est calculé sur base de coûts réels de mise en œuvre du FBP à Madagascar du projet PARN II. À Madagascar le nombre moyen de CSB publics par District sanitaire est égal à 25 CSB (annuaire des statistiques du secteur santé de Madagascar, 2024) [13].

Le modèle adapté pour la détection de fraudes des CSB du FBP doit être de « type agressif », avec un seuil de décision plus bas (seuil $\leq 0,19$), afin d'optimiser meilleur un compromis coût-risque. Le seuil optimal dépend du coût des erreurs. On abaisse le seuil de décision si le coûts Faux Négatifs est plus coûteux (C. Elkan, 2001) [14].

C. Analyse des indicateurs d'évaluation économique

Les indicateurs d'évaluation économique sont simulés à partir des performances observées sur le jeu de test (sensibilité et spécificité) du modèle XGBoost, puis extrapolé à une population de 25 CSB, en tenant compte la prévalence moyenne de fraude de 14% du District sanitaire d'Ambatolampy (2019-2021), et les coûts réels de la mise en œuvre du FBP.

Les résultats montrent que pour un District sanitaire de 25 CSB, le gain net de vérification ciblée par IA est estimé à \$145 963.

En comparant les deux méthodes de vérification des données de CSB, les résultats montrent l'évidence sur l'importance du changement structurel basé sur le coût de la vérification du FBP. Le taux de réduction des coûts égal à 75% nous indiquent une diminution substantielle des coûts de fonctionnement et d'investissement de l'évaluation ciblée par l'intelligence artificielle. Ce changement concerne le mode d'allocation des ressources publiques de vérification des données de formations sanitaires avant l'achat de performance.

La vérification classique des données des CSB du FBP mobilise des ressources importantes, en particulier des ressources humaines, financières, et temporelles, ainsi qu'un dispositif logistique conséquent. Dans les rapports internes du FBP à Madagascar, pendant la saison sèche, il faut planifier en moyenne 25 jours pour évaluer tous les CSB d'un District sanitaire sous contrat de performance. Durant la saison de pluie cette durée moyenne peut être allongée de plusieurs jours.

Sur le plan d'analyse de minimisation des coûts de vérification des données, le facteur d'efficacité est égal à 4. Les coûts de la vérification classique, sont quatre fois plus élevés que ceux de la vérification ciblée par l'intelligence artificielle. L'utilisation de l'intelligence artificielle permet à l'approche FBP de gagner en productivité organisationnelle et en efficacité. Cette minimisation des coûts est très recherchée dans les réformes de gestion publique du secteur sanitaire à ressources limitées comme à Madagascar.

Concernant le ratio coût résiduel, la vérification ciblée par l'intelligence artificielle est de 25 %. Il représente les coûts persistants liés à la vérification utilisant l'IA. Le rapport insiste sur le fait qu'une grande partie des dépenses de santé est inefficace ou évitable. Selon le rapport de l'OMS (2010) [15] entre 20 % et 40 % des dépenses de santé sont gaspillées en raison de l'inefficacité. L'utilisation de la vérification ciblée permet une réduction des coûts de 75 %.

Le retour sur investissement opérationnel est égal à 295%. Ce résultat renforce l'interprétation ci-dessus concernant l'efficacité des ressources engagées par rapport aux gains opérationnels. Ce niveau d'efficacité en général est cohérent avec les travaux de (A. Sheikh et al, 2025) [16] qui montrent que

l'utilisation de l'intelligence artificielle peut réallouer efficacement les ressources dans des environnements économiques complexes.

L'utilisation de l'intelligence artificielle permet de réduire en moyenne de 20% le nombre de CSB à auditer, dont l'avantage sera la diminution de nombre d'enquête communautaire à réaliser, et réduction de la durée d'évaluation des CSB dans un District sanitaire. L'IA permet de réduire les coûts d'investissement et de fonctionnement de la vérification des CSB au niveau du District sanitaire. Cette réduction de nombre d'enquête sera une opportunité pour améliorer la qualité d'enquête des 20% des CSB ciblés, en améliorant la motivation des enquêteurs communautaires. La sous rémunération des enquêteurs de l'approche FBP, est à l'origine de la baisse notable de la qualité des enquêtes, selon l'étude réalisée par (T. Tremblay et al, 2017) [17] au Burkina Faso, cette étude a confirmé le lien entre la qualité de l'enquêté et la sous-rémunération des enquêteurs communautaires.

La performance moyenne du modèle montre que, l'indicateur TPR économique (86 %), traduit la rentabilité à détecter les cas des CSB frauduleux, car le coût lié à une fraude est élevé. Ce résultat de TPR économique est cohérent à la baisse du seuil de décision (T. Fawcett, 2004) [18].

Quant à l'indicateur FPR économique (4%), le modèle déclenche 4 % de fausses alertes coûteuses. Il est possible d'optimiser ces indicateurs d'apprentissage sensible au coût, en baissant le seuil de décision (compromis coût-risque).

VIII. LIMITES DE L'ÉTUDE

- Il y a risque de surapprentissage, et de faible robustesse statistique en raison de la taille d'échantillon très faible (25 CSB du district d'Ambatolampy). Le choix du district d'Ambatolampy est justifié par la disponibilité de données de qualité, et des rapports techniques bien documentés par rapport aux autres districts sanitaires. Et en plus ce district sanitaire a plus de cinq ans d'expérience en FBP. Cette limite est liée essentiellement aux contraintes du terrain. Le risque de surapprentissage a été contrôlé par les paramètres suivant : profondeur limitée des arbres ($\text{max_depth} = 3$), faible taux d'apprentissage ($\text{eta} = 0,04$), séparation apprentissage/test et optimisation sur des données indépendantes et limitation de la complexité du modèle.
- L'intégrité limitée des données financières de la Pharmacie des CSB compromet leur exploitation statistique ;
- L'utilisation limitée à des données des 22 CSB du district d'Antanifotsy pour la validation externe est justifiée par des contraintes du terrain. Ce district dispose des données d'enquête auprès des usagers exploitables et bien documentées. Cette contrainte présente un risque de faiblesse de la robustesse statistique.

IX. CONCLUSION

Les coûts de la vérification des formations sanitaires du FBP mobilisent des ressources importantes. Pourtant plus de 80% des CSB vérifiés ou par vérification classique sont classés conformes. Dans le but d'optimiser les coûts de vérification des CSB, cette étude propose d'utiliser le XGBoost pour cibler les moins de 20% des CSB à risque de fraude, afin de rendre la vérification des CSB plus efficiente et plus efficace.

Les résultats montrent que les compromis de décision observés du modèle XGBoost (sensibilité vs spécificité) que le seuil de décision optimal est $\approx 0,19$. Avec ce seuil les bénéfices générés par l'IA sont maximaux pour un District sanitaire de 25 CSB. Pour une période d'activités de 12 trimestres du FBP, l'IA permet de gagner \$145 963 par District pour la vérification des données des 25 CSB, en réduisant jusqu'à 25% les coûts de vérification (ratio du coût résiduel). Le TPR économique d'utilisation de vérification ciblée est de 86%. La réduction de moins de 20% des CSB frauduleux à auditer permet d'optimiser les ressources logistiques engagées.

Cette étude vise à améliorer l'efficacité globale du FBP grâce à l'intégration de modèle d'IA dans l'optimisation économique, et de réduire les coûts opérationnels, et les contraintes logistiques de la vérification des données ou audit des données des CSB. Ce travail met en évidence l'importance de l'apprentissage automatique à l'économie de la décision basé sur le risque prédictif et le coût économique.

Les limites de l'étude sont essentiellement la qualité et la disponibilité des données de tous Districts enrôlés dans l'approche FBP.

Cette étude est très utile pour éclairer les responsables à la prise de décision économique dans le domaine de santé publique et l'allocation des ressources en financement public, car l'objectif du FBP est la réforme de la gestion publique axée sur les résultats.

La perspective future est l'amélioration des modèles IA utilisés pour cibler les CSB frauduleux comme le deep learning, ou les modèles hybrides, et le déploiement en temps réel.

Cette étude montre que l'intelligence artificielle constitue un levier puissant d'optimisation économique, permettant d'améliorer l'efficacité de la vérification du FBP en réduisant les coûts opérationnels, en mettant l'accent sur le compromis coût-performance.

X. RÉFÉRENCES

- [1] I. Mathauer, E. Dale, M. Jowett, J. Kutzin. (2019). *Purchasing health services for universal health coverage: how to make purchasing more strategic?*, World Health Organization, ISBN WHO/UHC/HGF/PolicyBrief 19.6. 2019.
- [2] CORDAID -SINA. (2010). PBF in action : Theories and Instruments, PBF Course Guide, The Hague. <https://www.sina-health.com/wp-content/uploads/PBFCourseBookSINATheoryActionEngVF100817.pdf>
- [3] C. Achir, A. Douari. (2024). Le management du risque à l'ère de l'émergence de l'intelligence artificielle, *Revue Française d'Économie et de Gestion*, Vol.5: N°1, p.52-77.
- [4] P. K. Kamuangu. (2024). A Review on Financial Fraud Detection using AI and Machine Learning, *Journal of Economics, Finance and Accounting Studies*, 6(1), 67-77. ISSN: 2709-0809, 2024.
- [5] T. Chen and C. Guestrin. (2016). XGBoost : A scalable tree boosting system, in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, San Francisco, CA, USA, p. 785–794. doi: 10.1145/2939672.2939785.
- [6] Corporate Finance Institute. (2023). Return on Investment (ROI): Formula, Examples and Interpretation, 2023. <https://corporatefinanceinstitute.com/resources/valuation/return-on-investment-roi/>
- [7] OECD. (2018). *Cost-Benefit Analysis and the Environment: Further Developments and Policy Use*, OECD Publishing, Paris.
- [8] World Bank. (2016). *Cost-Benefit Analysis in World Bank Projects*, Washington, DC.
- [9] M. J. Farrell. (1957). *The Measurement of Productive Efficiency*, " *Journal of the Royal Statistical Society*, vol. 120, no. 3, p. 253-290.
- [10] F. Provost and T. Fawcett. (2013). *Data Science for Business*, O'Reilly Media.
- [11] M. D. Ruopp, N. J. Perkins, B. W. Whitcomb, and E. F. Schisterman. (2008). Youden Index and Optimal Cut-Point Estimated from Observations Affected by a Lower Limit of Detection, *Biometrical Journal*, vol. 50, N°. 3, p. 419-430.
- [12] Institut National de la Statistique. (2024). Enquête Permanente auprès des Ménages (EPM) 2021–2022, Rapport INSTAT.
- [13] Ministère de la santé publique. (2024). Annuaire des statistiques du secteur santé de Madagascar, https://www.instat.mg/documents/upload/main/MSANP_AnnuaireStatistiques_2024.pdf
- [14] C. Elkan. (2001). *The Foundations of Cost-Sensitive Learning*, *Proceedings of the 17th International Joint Conference on Artificial Intelligence (IJCAI)*, p. 973-978.

- [15] World Health Organization. (2010). The World Health Report 2010: Health Systems Financing - The Path to Universal Coverage, WHO, Geneva. <https://iris.who.int/items/dfb3f56f-ff7f-421c-a010-dcb0cd75c78a>
- [16] A. Sheikh. (2025). AI-Powered Leadership in Supply Chain Management: Balancing Efficiency and Human Decision-Making," Journal of Global Economics, Management and Business Research, vol. 17, N°. 3, p. 476-485. DOI: 10.56557/jgembr/2025/v17i39998
- [17] M. Tremblay, L. Richard, J.-L. Zunzunegui, et al. (2017). *Twelve months of implementation of health care performance-based financing in Burkina Faso: A qualitative multiple case study* , *Int. J. Health Plann. Mgmt.*, vol. 33, no. 10, p. e153-e167, Oct. 2017. DOI: 10.1002/hpm.2438
- [18] T. Fawcett. (2004). *ROC Graphs: Notes and Practical Considerations for Data Mining*, *HP Laboratories*.